

MODELAGEM PREDITIVA COM APRENDIZAGEM DE MÁQUINA PARA A PRODUÇÃO DE CAFÉ DOS MUNICÍPIOS DE MINAS GERAIS

MARCELO SANTOS CARIELO¹, JOSÉ AUGUSTO DE LIMA PRESTES²,
WESLEI ALVIM DE TARSO MARINHO³

¹Doutor em Matemática em Aplicada pela Universidade Estadual de Campinas (Unicamp), atua na Facti - Fundação de Apoio à Capacitação em Tecnologia da Informação, Av. João Scarparo Netto, 84, Salas 20D - 22D, Unique Village Offices, Campinas-SP, 13080-655, Brasil, (19) 3211-5033, marcelo.santos@facti.com.br

²Mestrando em Política Científica e Tecnológica (Unicamp), atua na Facti - Fundação de Apoio à Capacitação em Tecnologia da Informação

³Mestre em Ciência da Computação pela Universidade Federal de Pernambuco (UFPE), atua na Facti - Fundação de Apoio à Capacitação em Tecnologia da Informação

Apresentado no
L Congresso Brasileiro de Engenharia Agrícola - CONBEA 2021
08 a 10 de novembro de 2021 - Congresso On-line

RESUMO: A produtividade agrícola de café no Brasil tem se beneficiado diretamente dos avanços científicos e tecnológicos, otimizando o uso de áreas para cultivo e o volume de produção. Neste contexto, destaca-se o estado de Minas Gerais (MG), maior produtor nacional de café arábica. O objetivo deste trabalho foi estimar a produção total de café dos municípios de MG, mediante o emprego de aprendizagem de máquina. Os dados utilizados foram coletados de bases públicas da EMBRAPA, IBGE e *WorldClim*, totalizando 17 variáveis de 24629 amostras, cobrindo o período de 1990 à 2018. Após a coleta, pré-tratamento e análise exploratória da base construída, os modelos foram treinados. A principal contribuição deste trabalho foi apresentar uma abordagem para estimar a produção total de café com alta capacidade preditiva, tendo alcançado $R^2 = 0.822$ e $RMSE = 0.177$ com o *Random Forest*. Os resultados obtidos mostram ainda a importância da base de dados em tal abordagem, além de fornecer subsídios para o entendimento da influência de diferentes classes de variáveis na produtividade.

PALAVRAS-CHAVE: *coffea arabica* L., produtividade cafeeira, inteligência artificial.

PREDICTIVE MODELING WITH MACHINE LEARNING FOR COFFEE PRODUCTION IN THE MUNICIPALITIES OF MINAS GERAIS

ABSTRACT: The agricultural productivity of coffee in Brazil has directly benefited from scientific and technological advances, optimizing the use of areas for cultivation and production volume. In this context, the state of Minas Gerais (MG) stands out, the largest national producer of arabica coffee. The objective of this work was to estimate the total coffee production in the municipalities of MG, based-on machine learning. The database used were collected from public databases of EMBRAPA, IBGE and *WorldClim*, resulting in 17 variables of 24629 samples, covering a period from 1990 to 2018. After collection, pre-treatment and exploratory analysis of the constructed dataset, the models were trained. The main contribution of this work was to present an approach to estimate the total coffee production with high predictive capacity, having reached $R^2 = 0.822$ and $RMSE = 0.177$ with *Random Forest*. The results obtained also show the importance of the dataset in such an

approach, in addition to providing subsidies for understanding the influence of different classes of variables on productivity.

KEYWORDS: *coffea arabica L.*, coffee productivity, artificial intelligence.

INTRODUÇÃO:

Dados da Companhia Nacional de Abastecimento (CONAB), publicados desde 2001, mostram uma tendência no aumento da produtividade do café total no Brasil (CONAB, 2021). Usualmente, a produtividade é caracterizada pela relação entre a quantidade de sacas de café produzido por hectares, contudo pesquisas têm investigado a influência de outros fatores.

Em FELEMA *et al.* (2013), a partir de dados do Instituto Brasileiro de Geografia e Estatística (IBGE), identificou-se uma correspondência direta entre o aumento da produtividade e fatores como, por exemplo, a qualidade dos insumos agropecuários, a instalação de benfeitorias, o emprego de máquinas e equipamentos, os níveis locais de chuva e pacotes tecnológicos.

Alguns dos avanços tecnocientíficos nesta área contam com o uso de algoritmos de inteligência artificial. Trabalhos fundamentados em aprendizagem de máquina mostram a eficiência desta abordagem para predição da ocorrência de pestes e pragas (APARECIDO *et al.*, 2020), detecção automática de doenças, estimativas de níveis de nutrientes e umidade em regiões de plantio (LIAKOS *et al.*, 2018). Resultados como esses contribuem para antecipar cenários relacionados aos dados de produção agrícola, suporte à tomada decisões e entendimento da produtividade.

Como explicam FISCHER *et al.* (2020), o processo de tomada de decisão no ambiente das atividades agrícolas não é trivial, pois existem variáveis controláveis (como, por exemplo, a quantidade de fertilizantes) e não controláveis que (ilustrativamente, o clima) que precisam ser combinadas entre si no processo; esta justaposição, por seu turno, permite associações que indicam relações de causa e efeito muitas vezes difíceis de serem previstas ou mesmo contraintuitivas. Tratando-se de dados processados em grande Volume, Variedade e Velocidade – caracteres que permitem definir o termo *Big Data* –, uma etapa fundamental em todo o processo é a definição e validação do modelo capaz de combinar e transformar essas bases em informações compreensíveis e úteis ao decisor.

O objetivo do presente trabalho foi construir uma base de dados que combina variáveis de produção, bioclimáticas e de geolocalização para desenvolver uma abordagem baseada em aprendizagem de máquina para então prever (HASTIE *et al.*, 2009) a produção de café total para cada um dos municípios de MG.

MATERIAL E MÉTODOS:

Parte fundamental para uma boa performance dos algoritmos de aprendizado de máquina é a base de dados utilizada para o treinamento (HASTIE *et al.*, 2009). De forma geral, é conhecido que o efeito do aumento no volume da base de dados utilizada para o treinamento dos algoritmos de aprendizagem de máquina tende a trazer benefícios para os modelos preditivos (CAI *et al.*, 2018). Em especial, a estruturação desses modelos preditivos busca permitir que se reduzam as incertezas sobre algo mediante a combinação entre variáveis e atributos – bem como a própria seleção prévia do atributo, com o propósito de incrementar a precisão da modelagem a ser estabelecida (PROVOST e FAWCETT, 2016).

No entanto, a escalabilidade do problema traz questões que precisam ser tratadas com cautela, como o nível de esparsidade e a qualidade da base de dados disponível (FORTUNY *et al.*, 2013). Como explicam PROVOST e FAWCETT (2016), a solução dessas questões geralmente dependerá do poder de processamento computacional, do recorte apropriado de um subconjunto informativo de dados ou daquilo contra o que se comparará os resultados obtidos (o que exige profundo conhecimento do negócio ou tema analisado).

O bom endereçamento dessas questões é fundamental para que a Aprendizagem de Máquina possa trazer os benefícios esperados no processo de tomada de decisão: sendo certo que os algoritmos desenvolvidos trabalham essencialmente com modelos de classificação ou regressão, a qualidade ou adequação dos dados interferirá diretamente naquilo que será processado, ajustado (ou treinado) e apresentado como resultado ao final (VALENTE *et al.*, 2020).

De acordo com VALENTE *et al.* (2020), por tais razões é que na etapa de Pré-Processamento de dados que devem ser realizadas tarefas de verificação e remoção de dados discrepantes (*outliers*), eliminação de dados redundantes e redução de dimensionalidade dos dados de treinamento, dentre outras.

Dessa forma, visando estimar a quantidade produzida de café total para cada município do estado de MG, de 2010 à 2017, a partir de períodos anteriores, foi coletado dados de produção (EMBRAPA, 2021), bioclima (FICK *et al.*, 2017) e geolocalização (IBGE, 2021) de cada um dos municípios de MG para o período entre 1994 e 2018. Isso corresponde a uma base composta de 24629 amostras e 17 variáveis: *Nome da Lavoura*, *Ano*, *Nome da UF*, *Sigla da Região Geográfica*, *Sigla da UF*, *Nome da Mesorregião*, *Nome da Microrregião*, *Nome do Município*, *Área Colhida* (mil hectares), *Quantidade Produzida* (mil toneladas), *Valor da Produção* (mil R\$), *Precipitação* (mm), *Temperatura Máxima* (°C), *Temperatura Mínima* (°C), *Longitude* (°), *Latitude* (°) e *Altitude* (m).

Os dados referentes a precipitação e temperaturas mínima e máxima, foram originalmente coletados em uma amostragem mensal. O *World Clim* (FICK *et al.*, 2017) disponibiliza esses valores em períodos de 10 anos, indo de 1969 a 2018, com uma resolução de 2.5 minutos, o equivalente a cerca de 21 km².

Esses dados foram coletados de forma a cobrir apenas o período de interesse, de 1990 a 2017, correspondente à base de dados das variáveis de produção. Isso totalizou um conjunto de 9 arquivos com tamanho variando de 3.4 GB a 3.9 GB, quando ainda compactados, e de 16.3 GB a 17.5 GB no seu formato descompactado. Para manipular esses arquivos foram empregadas estratégias que gerenciassem a memória RAM adequadamente. Cada um dos descompactados arquivos é referente a um período de 10 anos.

Dos arquivos descompactados foram extraídas as informações de interesse que complementaram os dados obtidos anteriormente sobre a produção de café dos municípios de MG. Embora coletadas em uma amostragem mensal, as informações sobre temperatura e precipitação foram tratadas para ficarem estruturados pela média anual.

Os dados de geolocalização (IBGE, 2021) coletados, também passaram por uma etapa de tratamento de forma a integrar a base de produção (EMBRAPA, 2021), estendendo a sua quantidade de variáveis, que passou a incluir informações sobre a latitude, longitude e altitude de cada um dos municípios de MG.

O resultado do tratamento dos dados de bioclima do *World Clim* (FICK *et al.*, 2017) foram combinados com os de geolocalização do IBGE (2021) e com os de produção da EMBRAPA (2021), formando a base de dados utilizada para a modelagem aqui proposta.

Após a construção da base para as análises preditivas, foi realizada a imputação de seus dados faltantes e codificação da variável categórica *Nome da Mesorregião* por meio da técnica *one-hot encode* (POTDAR *et al.*, 2017). Uma visão parcial da base de dados após esta etapa é apresentada nas tabelas 1 e 2:

TABELA 1. Visão parcial da base de dados obtida após combinação dos dados (primeiras 10 amostras e variáveis iniciais).

Ano	Área Colhida	Qtd.Produzida	Valor Produção	Precipitação	Temp. Máxima	Temp. Mínima	Longitude	Latitude	Altitude	Campo das Vertentes	Central Mineira	Jequitinhonha	
0	1990	423.693372	1270.735633	4.822330e+13	7.698391	29.107938	16.804196	-44.027948	-15.708871	745.378327	0.0	0.0	0.0
1	1990	13331.000000	9352.000000	1.530327e+14	17.158999	26.069689	13.910889	-42.206850	-17.104064	460.764863	0.0	0.0	0.0
2	1990	14.000000	28.000000	5.600000e+01	13.093644	28.608236	16.633344	-42.471395	-21.533785	191.228225	0.0	0.0	0.0
3	1990	423.693372	1270.735633	4.822330e+13	11.784220	29.348553	16.819887	-50.575290	-19.547777	425.836745	0.0	0.0	0.0
4	1990	6096.000000	1885.000000	3.304582e+14	15.922064	24.678726	13.434116	-46.417029	-21.126652	1125.166247	0.0	0.0	0.0
5	1990	35.000000	35.000000	2.863636e+14	16.342461	25.713026	14.896760	-43.586382	-21.033083	831.855729	1.0	0.0	0.0
6	1990	165.000000	203.000000	4.060000e+02	17.174050	25.826547	13.923967	-44.906106	-21.512320	946.006515	1.0	0.0	0.0
7	1990	83.000000	89.000000	4.712727e+14	16.023397	27.748563	14.817615	-44.985579	-19.875867	738.494373	0.0	0.0	0.0
8	1990	58.000000	73.000000	1.291636e+14	16.499062	22.683278	12.726200	-46.322162	-22.858190	899.927683	0.0	0.0	0.0
9	1990	22.000000	396.000000	7.228727e+14	16.714843	27.393485	14.689341	-44.605380	-19.864738	803.711403	0.0	0.0	0.0

TABELA 2. Visão parcial da base de dados obtida após combinação dos dados (continuação, restante das variáveis).

Longitude	Latitude	Altitude	Campo das Vertentes	Central Mineira	Jequitinhonha	Metropolitana de Belo Horizonte	Noroeste de Minas	Norte de Minas	Oeste de Minas	Sul/Sudoeste de Minas	Triângulo Mineiro/Alto Paranaíba	Vale do Mucuri	Vale do Rio Doce	Zona da Mata
-44.027948	-15.708871	745.378327	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0
-42.206850	-17.104064	460.764863	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0
-42.471395	-21.533785	191.228225	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0
-50.575290	-19.547777	425.836745	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0
-46.417029	-21.126652	1125.166247	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0
-43.586382	-21.033083	831.855729	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
-44.906106	-21.512320	946.006515	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
-44.985579	-19.875867	738.494373	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0
-46.322162	-22.858190	899.927683	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0
-44.605380	-19.864738	803.711403	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0

Além disso, os dados foram filtrados pelo período de interesse, eliminando-se os *outliers*. Também foram aplicadas transformações logarítmicas nas variáveis *Área Colhida*, *Quantidade Produzida* e *Valor da Produção*. Essa etapa assegurou que o coeficiente de variação das variáveis incluídas no modelo ficasse em margens convenientes para as análises.

Com isso obteve-se a base de dados pré-tratada para a etapa de treinamento, composta por 14263 amostras e 22 variáveis: *Ano*, *Área Colhida* (mil hectares), *Quantidade Produzida* (mil toneladas), *Valor da Produção* (mil R\$), *Precipitação* (mm), *Temperatura Máxima* (°C), *Temperatura Mínima* (°C), *Longitude* (°), *Latitude* (°), *Altitude* (m), *Campo das Vertentes*, *Central Mineira*, *Jequitinhonha*, *Metropolitana de Belo Horizonte*, *Noroeste de Minas*, *Norte de Minas*, *Oeste de Minas*, *Sul/Sudoeste de Minas*, *Triângulo Mineiro/Alto Paranaíba*, *Vale do Mucuri*, *Vale do Rio Doce* e *Zona da Mata*.

As novas variáveis, introduzidas pelo tratamento da variável categórica *Nome da Mesorregião*, correspondem às mesorregiões de MG. Após o pré-tratamento desses dados realizou-se a análise da distribuição e correlação entre as 22 variáveis.

Em seguida, esta base foi dividida em duas partes: 70% para treinamento dos algoritmos (14263 amostras; 1994 a 2009/2010) e 30% (6113 amostras; 2010 a 2017) para os testes. As amostras de testes servem para avaliar se as estimativas fornecidas pelos modelos treinados estão ou não adequadas.

Uma vez realizada a divisão, os dados de treino foram padronizados e seis modelos (HASTIE, 2009) foram treinados sob estes dados: *Regressão Linear*, *Huber Regressor*, *RANSAC Regressor*, *XGBoost*, *Random Forest* e *Multilayer Perceptron*.

Por fim, as previsões e comparações foram realizadas com os valores de teste. Para realizar comparações nas escalas originais, a inversa das transformações logarítmicas foi aplicada aos dados de interesse.

As etapas computacionais deste trabalho usaram as linguagens de programação *Python* e *R*, valendo-se de implementações já consolidadas para modelos de aprendizagem de máquina (PEDREGOSA, 2011).

RESULTADOS E DISCUSSÃO:

Parte dos resultados obtidos neste trabalho foi a base de dados construída, composta de 24629 amostras de 17 variáveis que combinam características da produção de café, bioclimáticas e de geolocalização para cada um dos municípios de MG, durante todo período estudado (vide tabelas 1 e 2). Por meio da análise desta base é possível identificar a influência de diferentes variáveis na produção cafeeira, bem como em sua produtividade.

A FIGURA 1 mostra as estimativas dos modelos treinados e os valores reais para cada uma das 6113 amostras de teste, referentes à produção de café entre 2010 e 2017. Os eixos das abscissas e coordenadas correspondem, respectivamente, aos valores reais e valores estimados. Pelos gráficos nota-se a alta performance do algoritmo *Random Forest*.

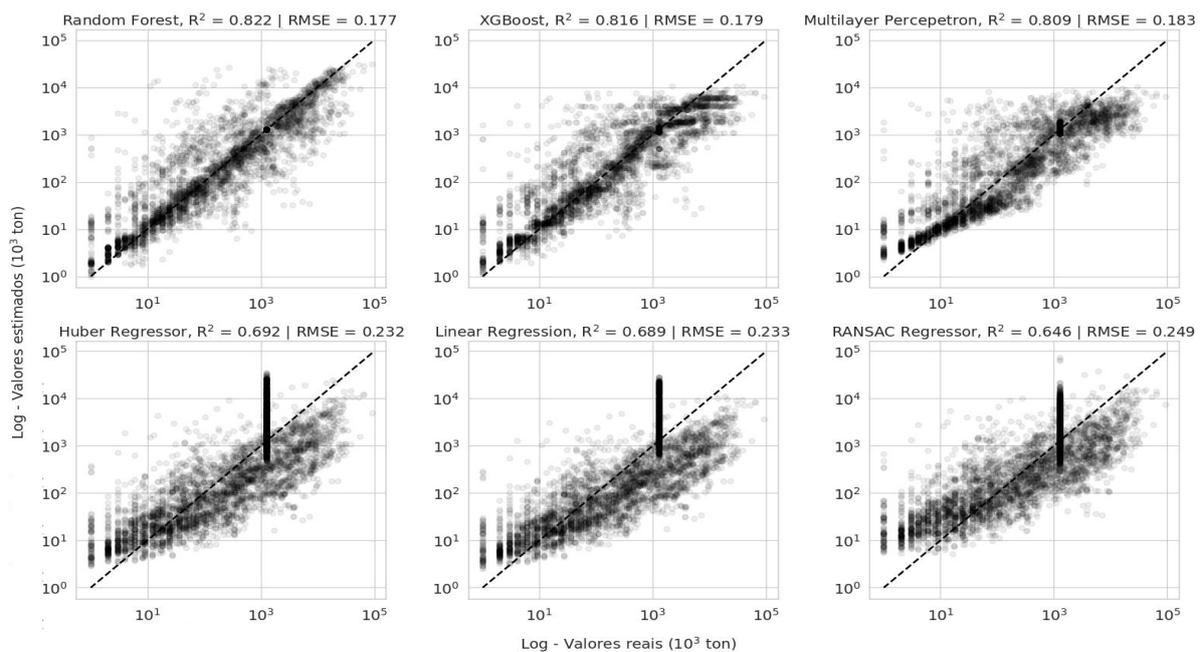


FIGURA 1. Estimativas das quantidades de café produzida e as quantidades reais anualmente.

Além de possuir alta capacidade de explicar a variância das previsões realizadas para o período de teste, o erro nas estimativas é baixo. Os gráficos mostram que, para o modelo *Random Forest*, há uma alta concentração de pontos em torno da diagonal em tracejado, correspondente à alta performance nos testes. Por outro lado, o modelo *RANSAC Regressor* sobrestimou os valores mais baixos e subestimou os valores mais altos, o que condiz com os seus valores mais baixos de R^2 e $RMSE$.

TABELA 3. Síntese das performances para as estimativas da produção de café.

MODELO	R²	RMSE (10³ ton)
<i>Random Forest</i>	0.822	0.177
<i>XGBoost</i>	0.816	0.179
<i>Multilayer Perceptron</i>	0.809	0.183
<i>Huber Regressor</i>	0.692	0.232
<i>Regressão Linear</i>	0.689	0.233
<i>RANSAC Regressor</i>	0.646	0.249

Previamente, o problema aqui estudado foi investigado levando-se em conta um subconjunto das variáveis atuais (CARIELO *et al.*, 2020). Na ocasião não foram consideradas as bioclimáticas e de geolocalização. Mesmo com uma quantidade reduzida, as performances obtidas para as estimativas da quantidade produzida de café foram satisfatórias, atingindo valores $R^2 = 0.63$ e $RMSE = 0.87$ com o *XGBoost*. O presente trabalho traz melhorias para modelagem desse problema, conforme mostra a TABELA 3.

O acréscimo de novas variáveis relacionadas a produtividade cafeeira para cada um dos municípios de MG trouxe informações de relevância para a modelagem aqui proposta. A contribuição obtida pode complementar análises da produtividade que levem em conta aspectos preditivos e descritivos, assim como variáveis que capturem aspectos de relevância do problema.

Neste sentido, uma forma de se aplicar o modelo construído é filtrando a base de dados inicial para algum município de MG em particular e, então, utilizar o modelo previamente treinado para estimar a produção do período de interesse. De fato, é possível selecionar qualquer subconjunto de dados que tenha proximidade com a base de treinamento para realizar a estimativa de valores futuros.

Para ilustrar o desempenho do modelo obtido, aplicamos o modelo construído com a abordagem proposta a um subconjunto selecionado aleatoriamente, formado por 20% das 6113 amostras utilizadas para testes. A seguir temos os valores que descrevem os resultados obtidos nas estimativas.

TABELA 4. Dados estatísticos da quantidade de café produzida referentes às 1498 (20%) amostras escolhidas aleatoriamente e as estimativas com o *Random Forest*.

	Observado (10³ ton)	Estimado (10³ ton)
<i>Média</i>	1582.644507	1493.030189
<i>Mínimo</i>	1.000000	1.747786
<i>25%</i>	31.250000	35.755051
<i>50%</i>	669.000000	674.101970
<i>75%</i>	1270.735633	1270.735633
<i>Máximo</i>	31746.000000	31624.779615

Comparando as médias e percentis da TABELA 4, notamos mais uma vez que as estimativas fornecidas pela modelagem preditiva com o *Random Forest* mantêm-se adequadas.

CONCLUSÕES:

Os resultados obtidos neste trabalho apresentam uma abordagem baseada em dados para a análise preditiva da produção cafeeira. A combinação de fatores produtivos, bioclimáticos e geoespaciais pode ser aprofundada para o entendimento mais detalhado da produtividade.

A alta performance para as estimativas da quantidade de produção de café anual para cada um dos municípios de MG, entre 2010 e 2017, a partir de dados passados, indica que a abordagem aqui proposta pode servir como base para novos estudos, incluindo outros períodos, regiões e variáveis.

AGRADECIMENTOS:

Os autores agradecem à Facti - Fundação de Apoio à Capacitação em Tecnologia da Informação, que apoiou a execução deste trabalho interno de Pesquisa, Desenvolvimento e Inovação (PD&I).

REFERÊNCIAS:

APARECIDO, L. E. O. *et al.* Machine Learning Algorithms for Forecasting the Incidence of Coffea Arabica Pests and Diseases. *International Journal of Biometeorology*, pp.1-18, 2020.

CAI, J., LUO, J., WANG, S., YANG, S. Feature selection in machine learning: A new perspective. *Neurocomputing*, v. 300, pp. 70-79, 2018.

CARIELO, M. S., MARINHO, W. A. T., PRESTES, J. A. L. Uma Análise Exploratória da Produção de Café do Estado de Minas Gerais através de Técnicas de Aprendizagem de Máquina. In: **Congresso Brasileiro de Engenharia Agrícola**, 49, 2020, on-line.

CONAB. Companhia Nacional de Abastecimento. **Acompanhamento da safra brasileira: café**. v.8, n.2, 2021. Disponível em: <<https://www.conab.gov.br>>. Acesso em: 21 de junho de 2021.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Agropensa**. Disponível em: <<https://www.embrapa.br/agropensa/bases-de-dados>>. Acesso em: 21 de junho de 2021.

FELEMA, J., RAIHER, A. P., FERREIRA, C. R. Agropecuária brasileira: desempenho regional e determinantes de produtividade. *Revista de Economia e Sociologia Rural*, v. 51, n.3, pp. 555-573, 2013.

FICK, S., HIJMANS, R. J. WorldClim 2: New 1-km Spatial Resolution Climate Surfaces for Global Land Areas. *International Journal of Climatology*, v. 37, n. 12, pp. 4302-4315, 2017.

FISCHER, H., SALVI, J. V., GARCIA, L. H. T. **Transmissão de Dados, Computação nas Nuvens e Big Data**. In: *A Agricultura Digital*. Queiroz, D. M., Valente, D. S. M., Pinto, F. A. C., Borém, A. (Eds). Universidade Federal de Viçosa. Cap. 12, pp. 239-257, 2020.

FORTUNY, E. F., MARTENS, D., PROVOST, F. Predictive Modeling with Big Data: Is Bigger Really Better?. *Big Data*, v. 1(4), pp. 215-226, 2013.

HASTIE, T., TISHIRANI, R., FRIEDMAN, J. **The Elements of Statistical Learning**. Springer Series in Statistics, 2009.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Downloads**. Disponível em: <<https://www.ibge.gov.br/estatisticas/downloads-estatisticas.html>>. Acesso em: 21 de junho de 2021.

LIAKOS, K. G., BUSATO, P., MOSHOU, D., PEARSON, S., BOCHTI, D. Machine Learning in Agriculture: A Review. *Sensors*, v. 18, n. 8, pp. 2674-2703, 2018.

PEDREGOSA, F. *et al.* Scikit-learn: Machine Learning in Python. **The Journal of Machine Learning Research**, v. 2, pp. 2825-2830, 2011.

POTDAR, K., PARDAWALA, T. S., PAI, C. D. A Comparative Study of Categorical Variable Encoding Techniques for Neural Network Classifiers. *International Journal of Computer Applications*, v. 175, n. 4, pp. 7-9, 2017.

PROVOST, F., FAWCETT, T. **Data Science para Negócios**. Alta Books, 2016.

VALENTE, D. S. M., QUEIROZ, D. M., PEREIRA, G. W. **Machine Learning**. In: *A Agricultura Digital*. Queiroz, D. M., Valente, D. S. M., Pinto, F. A. C., Borém, A. (Eds). Universidade Federal de Viçosa. Cap. 13, pp. 258-285, 2020.