

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL**

**MODELAGEM AGROMETEOROLÓGICA POR INTELIGÊNCIA ARTIFICIAL PARA
PREVISÃO DA PRODUTIVIDADE DE PALMEIRAS NA AMAZÔNIA ORIENTAL**

José Reinaldo da Silva Cabral de Moraes
Engenheiro Agrônomo

2021

RESSALVA

Atendendo solicitação do(a)
autor(a), o texto completo desta tese
será disponibilizado somente a partir
de 02/06/2023.

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL**

**MODELAGEM AGROMETEOROLÓGICA POR INTELIGÊNCIA ARTIFICIAL PARA
PREVISÃO DA PRODUTIVIDADE DE PALMEIRAS NA AMAZÔNIA ORIENTAL**

**José Reinaldo da Silva Cabral de Moraes
Orientador: Prof. Dr. Glauco de Souza Rolim**

Tese apresentada à Faculdade de Ciências Agrárias e Veterinárias – UNESP, Câmpus de Jaboticabal, como parte das exigências para a obtenção do título de Doutor em Agronomia (Produção Vegetal).

M827m Moraes, José Reinaldo da Silva Cabral de
Modelagem agrometeorológica por inteligência artificial para
previsão da produtividade de palmeiras na Amazônia Oriental /
José Reinaldo da Silva Cabral de Moraes. -- Jaboticabal, 2021
139 p.

Tese (doutorado) - Universidade Estadual Paulista (Unesp),
Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal
Orientador: Glauco de Souza Rolim

1. Agrometeorologia. 2. Amazônia brasileira. 3. Arecaceae.
4. Machine Learning. 5. Python. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp.
Biblioteca da Faculdade de Ciências Agrárias e Veterinárias,
Jaboticabal. Dados fornecidos pelo autor(a).

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: **MODELAGEM AGROMETEOROLÓGICA POR INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DA PRODUTIVIDADE DE PALMEIRAS NA AMAZÔNIA ORIENTAL**

AUTOR: JOSÉ REINALDO DA SILVA CABRAL DE MORAES

ORIENTADOR: GLAUCO DE SOUZA ROLIM

Aprovado como parte das exigências para obtenção do Título de Doutor em AGRONOMIA (PRODUÇÃO VEGETAL), pela Comissão Examinadora:



Assinado de forma digital por
Glauco de Souza Rolim
Dados: 2021.08.04 06:45:05
-03'00'

Prof. Dr. GLAUCO DE SOUZA ROLIM (Participação Virtual)
Engenharia e Ciências Exatas / FCAV / UNESP - Jaboticabal

Pesquisadora Dra. LUCIETA GUERREIRO MARTORANO (Participação Virtual)
NAPT-Embrapa Amazônia Oriental / Belém/PA



Assinado de forma digital por Glauco de Souza Rolim
Dados: 2021.08.04
06:45:36 -03'00'

Prof. Dr. ROGÉRIO TEIXEIRA DE FARIA (Participação Virtual)
Departamento de Engenharia e Ciências Exatas (DECEX) / FCAV / UNESP - Jaboticabal



Assinado de forma digital por Glauco de Souza Rolim
Dados: 2021.08.04
06:45:54 -03'00'

Prof. Dr. LUCAS EDUARDO DE OLIVEIRA APARECIDO (Participação Virtual)
Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais - Campus Muzambinho / Muzambinho/MG



Assinado de forma digital por Glauco de Souza Rolim
Dados: 2021.08.04
06:46:11 -03'00'

Prof. Dr. ALEXANDRE DAL PAI (Participação Virtual)
Bioprocessos e Biotecnologia / Faculdade de Ciências Agronômicas de Botucatu - UNESP



Assinado de forma digital por Glauco de Souza Rolim
Dados: 2021.08.04
06:46:36 -03'00'

Jaboticabal, 02 de junho de 2021

DADOS CURRICULARES DO AUTOR

JOSÉ REINALDO DA SILVA CABRAL DE MORAES - Nascido em Castanhal, Pará, no dia 27 de abril de 1992, filho de José da Silva Moraes e Lilia da Silva Cabral de Moraes, natural de Castanhal, Pará. cursou o ensino fundamental no colégio estadual Aristedes Santa Rosa, no município de Inhangapi, Pará e o ensino médio no Instituto de Educação Darwin, no município de Castanhal, Pará, tendo finalizado no ano de 2009. Ingressou no ensino superior no ano de 2010 no curso de Engenharia Agrônômica pela Universidade Federal Rural da Amazônia (UFRA), Campus Belém, obtendo o título de Engenheiro Agrônomo em janeiro de 2015. Durante a graduação foi bolsista do Programa de Educação Tutorial (PET) Agronomia, sob a tutoria do Prof. Dr. Carlos Augusto Cordeiro Costa por quatro anos e realizando iniciação científica na Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) Amazônia Oriental, também durante quatro anos, na área de Agrometeorologia, sob orientação da pesquisadora Dra. Lucieta Guerreiro Martorano. Realizou durante um ano estágio curricular na área de agrometeorologia e modelagem na UFRA, sob a orientação do Prof. Dr. Paulo Jorge de Oliveira Ponte de Souza, desenvolvendo seu trabalho de conclusão de curso com a calibração do modelo DSSAT para o feijão caupi. Em agosto de 2015, iniciou o curso de Mestrado em Agronomia, no Programa de Produção Vegetal, na área de Modelagem Agrometeorológica, pela Universidade Estadual Paulista “Júlio de Mesquita Filho” – Campus de Jaboticabal, São Paulo, sob a orientação do Prof. Dr. Glauco de Souza Rolim, concluindo no ano de 2017. No ano de 2017 iniciou o doutorado na mesma instituição sob a orientação do professor Glauco Rolim, submetendo sua tese em abril de 2021 à banca examinadora para obtenção do título de doutor em Agronomia.

O mundo é um livro, e quem fica sentado em
casa lê somente uma página.

Santo Agostinho

Aos meus pais, José Moraes e Lilia Moraes por
toda dedicação, amor e carinho que me foi dado,
e com seus sacrifícios, me proporcionaram
caminhos de muitas conquistas e realizações.
Minhas vitórias são graças a vocês.

DEDICO

Ao meu Avô Sebastião de Oliveira Moraes (*In memorian*). Que
apesar do pouco tempo que passamos juntos,
foi o suficiente para formar homem que sou hoje.
A minha noiva Aline Michelle da Silva Barbosa,
pelo seu carinho, amor, dedicação e apoio
incondicional nas batalhas da vida.

OFEREÇO

AGRADECIMENTOS

A Deus, por ter me guiado e protegido, mostrando sempre o melhor caminho a seguir.

Ao professor Glauco Rolim, orientador e amigo. Seus ensinamentos científicos e de vida me moldaram como profissional e pessoa, obrigado por toda paciência e parceria durante esses anos de mestrado e doutorado.

À professora Lucieta Guerreiro Martorano, pela amizade, confiança e por ter acreditado no meu potencial no início da minha graduação. Nossos caminhos terem se cruzado logo no começo da minha vida acadêmica e científica, foi fundamental para eu enxergar outras oportunidades e desafios.

Agradeço a Universidade Federal Rural da Amazônia (UFRA), instituição que me formei como engenheiro agrônomo e conquistei grandes amigos. Aos professores dessa universidade, em especial ao professor Paulo Jorge de Oliveira Ponte de Souza, pelas excelentes aulas de agrometeorologia na graduação, e posteriormente pela orientação no meu trabalho de conclusão de curso.

Ao Programa de Educação Tutorial (PET) Agronomia, em especial ao professor Carlos Augusto Cordeiro Costa, pelos conselhos, anos de amizade, ensinamentos. Este programa o qual fui bolsista durante quatro anos foi fundamental para minha formação como profissional. Também agradeço aos amigos bolsistas do PET, por toda convivência, viagens, experimentos de campo e amizade.

Registro meus agradecimentos a minha família, em especial as minhas irmãs, Liliane Moraes, Josi Moraes e Viviane Feio, por todo carinho, apoio e pelos sobrinhos maravilhosos que já me deram. Aos meus tios Reinado Moraes e Ieda Terra, por todo acolhimento, confiança e carinho.

A minha madrinha Ambrósia Marinho (*In memoriam*) que sempre acreditou e torceu pelo meu sucesso. À minha avó paterna, Raimunda Monteiro da Silva Moraes e materna, Nazaré Cabral, e meus avós de coração, Maria das Dores Terra e Antônio Terra da Trindade (*In memoriam*), pelos ensinamentos e carinhos frequentes.

Meus agradecimentos aos funcionários do departamento de ciências exatas da UNESP, em especial aos amigos Carlão, Vanessa, Zezé, Shirlei e Adriana. E aos amigos Bruna, Gustavo, Daniel e Mara.

Aos amigos do grupo de pesquisa GAS da UNESP, Lucas Aparecido, Taynara Valeriano, Victor Moreto, Kamila Meneses, João Trevizoli, Valter e Aline.

Aos irmãos que também passaram por Jaboticabal e foram trilhar novos caminhos, Daniel Pinheiro, Francisco Carlos, Flávio José e Raphael Leone. Amizades construídas durante a pós-graduação e que levo para vida. Registro também meus agradecimentos aos companheiros do Galáticos futebol, amigos que conquistei durante o mestrado e doutorado.

Aos amigos do Instituto Federal do Mato Grosso do Sul, em especial ao Cícero Teixeira, Gustavo Valente, Daniel Zimmermann, Matheus Bornelli, pela amizade e apoio no início da minha carreira docente.

À Embrapa Amazônia Oriental, em especial aos pesquisadores Dra. Socorro Padilha e Dr. João Tomé, pela concessão dos dados de campo para a realização dessa pesquisa. Aos amigos do Laboratório de Agrometeorologia da Embrapa Amazônia Oriental, por toda parceria científica, carinho e amizade.

À empresa Sococo em nome do Dr. Paulo Lins, assim como a empresa Marboges em nome do Dr. Abreu Pina, pelo fornecimento dos dados de campo para realização da minha tese.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

A todos que contribuíram para minha formação de vida e profissional, meus sinceros agradecimentos.

SUMÁRIO

RESUMO.....	iii
ABSTRACT.....	iv
CAPÍTULO 1 – CONSIDERAÇÕES GERAIS.....	1
1.1 Palma de óleo.....	1
1.2 Coqueiro	4
1.3 Açaizeiro.....	5
1.4 Inteligência artificial.....	6
REFERÊNCIAS.....	10
CAPÍTULO 2 – Modelagem Agrometeorológica a partir de inteligência artificial para prever a produtividade da Palma de óleo no estado do Pará, Amazônia. 19	
2.1 INTRODUÇÃO.....	21
2.2 MATERIAL E MÉTODOS.....	24
2.2.1 Base de dados.....	24
2.2.2 Componentes de água no solo.....	28
2.2.3 Caracterização fenológicas da palma de óleo.....	30
2.2.4 Modelos de Machine Learning.....	32
2.2.5 Análise de dados.....	35
2.3 RESULTADOS.....	36
2.4 DISCUSSÃO.....	54
2.5 CONCLUSÃO.....	59
2.6 REFERÊNCIAS.....	59
CAPÍTULO 3 – Previsão de produtividade de frutos de açaí (Euterpe oleracea Mart.) na região Nordeste paraense na Amazônia Oriental modelado por inteligência artificial.....	68
3.1 INTRODUÇÃO.....	70
3.2 MATERIAL E MÉTODOS.....	72
3.2.1 Caracterização fenológica do açaizeiro.....	76
3.2.2 Modelos de Machine learning.....	79
3.3 RESULTADOS E DISCUSSÃO.....	82
3.4 CONCLUSÃO.....	94

3.5 REFERÊNCIAS.....	94
CAPÍTULO 4 – Previsão agrometeorológica da produtividade do coqueiro modelado por Machine Learning.....	104
4.1 INTRODUÇÃO.....	106
4.2 MATERIAL E MÉTODOS.....	108
4.2.1 Área de estudo e origem dos dados.....	108
4.2.1 Caracterização fenológica do coqueiro.....	114
4.2.2 Modelos de Machine Learning.....	115
4.2.3 Processamento gráfico e estatísticos.....	116
4.3 RESULTADOS.....	117
4.4 DISCUSSÃO.....	128
4.5 CONCLUSÃO.....	131
4.6 REFERÊNCIAS.....	132

MODELAGEM AGROMETEOROLÓGICA POR INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DA PRODUTIVIDADE DE PALMEIRAS NA AMAZÔNIA ORIENTAL

RESUMO

A expansão de palmeiras de alto valor comercial e industrial como a palma de óleo, o açazeiro e o coqueiro, necessitam de informações e estratégias sustentáveis para seus sistemas de cultivos. Modelos agrometeorológicos atuam como uma ferramenta exploratória para os tomadores de decisão e aliado a inteligência artificial (IA) auxiliam no planejamento do uso da terra para cultivos agrícolas anuais e/ou perenes. Tais métodos desempenham um papel importante na previsão de produtividade, no entanto, poucas pesquisas têm sido aplicadas visando a modelagem de palmeiras, que sejam suficientemente simples e ao mesmo tempo incorporem o conhecimento fenológico e climático suficientes para ser estudada em locais com diferentes condições de crescimento e práticas de manejo. Neste sentido, objetiva-se avaliar o desempenho de modelos de IA na modelagem agrometeorológica para previsão da produtividade da palma de óleo, açaí e do coco na Amazônia Oriental. O estudo foi realizado em várias regiões do estado do Pará. Os dados de produtividade de palma de óleo e coco foram disponibilizados por empresas produtoras situadas na Amazônia, e de açaí de áreas experimentais da Embrapa Amazônia oriental. Foram utilizados diferentes modelos de IA para prever a produtividade das culturas. Para todos os modelos, foram separados 70% dos dados para treinamento e 30% para teste. Os modelos ajustados foram: Regressão linear múltipla (RLM), Random Forest (RF), Redes neurais artificiais Multilayer Perceptron (MLP) e Support Vector Machine de base radial RBF (SVM_RBF), Linear (SVM_Linear) e Polinomial (SVM_Poly), usando a linguagem de programação Python. Os modelos foram avaliados por meio da acurácia, precisão e tendência, comparando dados observados e previstos. Os dados observados em campo e obtidos pelos modelos de IA foram comparados pelo R^2 , MAPE, RMSE e ME. Modelos de IA com 4 meses antes da colheita apresentaram acurácia média (MAPE) de 22% para previsão de produtividade da palma de óleo. Para o açaí, variaram de 4 a 7 meses entre os diferentes tipos de manejo e épocas do ano com MAPE médio igual a 19%. Para o coqueiro, os resultados apontaram previsões com até 11 meses antes da colheita com MAPE médio igual a 15%. Houve uma perda de precisão dos modelos ao prever dados extremos, com subestimação na previsão em situações de altas produtividades e superestimação em baixas produtividades. No geral, os modelos de IA demonstraram desempenho importante para prever a produtividade das palmeiras estudadas, subsidiando produtores, agroindústrias e outros planejadores a melhor tomada de decisão.

Palavras-chave: Agrometeorologia, Amazônia brasileira, Arecaceae, Machine Learning, Python

AGROMETEOROLOGICAL MODELING WITH ARTIFICIAL INTELLIGENCE IN FORECASTING PALM YIELD IN THE EASTERN AMAZON

ABSTRACT

The expansion of high commercial and industrial value palm trees such as the oil palm, the açazeiro and the coconut palm, require information and sustainable strategies for their cropping systems. Agrometeorological models consist of an exploratory tool for decision makers and allied with artificial intelligence (AI) assist in land use planning for annual and/or perennial agricultural crops. This methods play an important role in yield prediction, however, few researches have been applied aiming at palm tree modeling that are simple enough and at the same time incorporate enough phenological and climatic knowledge to be studied in locations with different growing conditions and management practices. This, we aimed to evaluate the performance of AI models in agrometeorological modeling for predicting the yield of oil palm, acai and coconut in the Eastern Amazon. The study was conducted in several regions of the state of Pará, Brazil. Yield data for oil palm and coconut were provided by production companies located in the Amazon, and for açai from experimental areas of Embrapa Amazônia oriental. Several AI models were used to predict crop yield. We use 70% of the data to calibrate and 30% to test the AI models. The fitted AI models were: Multiple Linear Regression (MLR), Random Forest (RF), Multilayer Perceptron (MLP) artificial neural networks, and Support Vector Machine of radial RBF (SVM_RBF), Linear (SVM_Linear) and Polynomial (SVM_Poly) bases. We using the Python programming language to perform the analysis. The models were evaluated using accuracy, precision, and trend, comparing observed and predicted data. Field-observed data and data obtained by the AI models were compared by R^2 , MAPE, RMSE, and ME. AI models with 4 months before harvest showed average accuracy (MAPE) of 22% for predicting oil palm yields. We observed that it ranged from 4 to 7 months between the different types of management and times of the year with an average MAPE equal to 19% for açai. As for the coconut palm, the results showed predictions up to 11 months before harvest with an average MAPE equal to 15%. There was a loss of accuracy of the models when predicting extreme data, with underestimation in the prediction in situations of high yields and overestimation in low yields. Overall, the AI models demonstrated an important performance in predicting the yield of the studied palms, supporting producers, agro-industries and other planners to make better decisions.

Keywords: Agrometeorology, Brazilian Amazon, Arecaceae, Machine Learning, Python

CAPÍTULO 1 – CONSIDERAÇÕES GERAIS

A maioria das palmeiras se desenvolve em ecossistemas tropicais (Eiserhardt et al., 2011) sendo possível a expansão desses cultivos no Brasil, principalmente em áreas antropizadas. Os climas tropicais são caracterizados por padrões de temperatura previsíveis e com pequena amplitude térmica (Moron; Robertson; Wang, 2019). Contudo, os regimes de precipitação pluvial não tendem a ser simples e previsíveis, existindo grandes variações no ano e entre os anos (Moraes et al., 2020).

Os produtores agrícolas, agroindústrias e outros, necessitam ter alta produtividade e sustentabilidade em seus negócios. Neste sentido, conhecer a variabilidade do clima por meio de modelos agrometeorológicos de forma prévia na cadeia produtiva de qualquer cultura, é fundamental para estabelecer estratégias e melhores tomada de decisão (Klompenburg et al., 2020).

Dentre as palmeiras de alto valor comercial e de produção, destaca-se a palma de óleo o coqueiro e o açaizeiro, do gênero *Elaeis*, *Cocos* e *Euterpe*, respectivamente, que tem na Amazônia brasileira suas principais áreas de produção e comercialização. Diversos trabalhos vêm estudando a influência do clima no desenvolvimento e efeitos na produção dessas culturas, entre esses destaca-se, Benezoli et al. (2021), Liu et al. (2021) e Oettli et al. (2018) para palma de óleo, Santos et al. (2020), Samarasinghe et al. (2018) e Pathmeswaran et al. (2018) para o coqueiro e Moraes et al. (2020) e Viana et al. (2020) para o açaizeiro.

1.1 Palma de óleo

A palma de óleo (*Elaeis guineensis* Jacq.) uma das culturas oleaginosas mais importantes do mundo, originária da África Tropical. Trazida para o Brasil pelos escravos, se adaptou ao clima tropical úmido da Bahia, mas foi na região amazônica que o cultivo obteve as maiores produtividades (Vijay et al., 2016). A produção de óleo de palma é cinco vezes maior por unidade de terra do que outras culturas oleaginosas, como a soja, que, juntamente com a crescente demanda global de óleo vegetal e biocombustíveis, impulsiona sua lucratividade (Lamade et al., 2016).

Entre as culturas com maior expansão de área colhida nos trópicos úmido, a palma de óleo se destaca entre as três maiores, com crescimento de 176% entre os anos de 2000 a 2019 (Figura 1), sendo que 87% da produção é concentrada principalmente no Sudeste Asiático (FAO, 2021). No Brasil a região do nordeste paraense concentra aproximadamente 98% da produção, com mais de 160 mil hectares colhidos (Figura 2) (IBGE 2021).

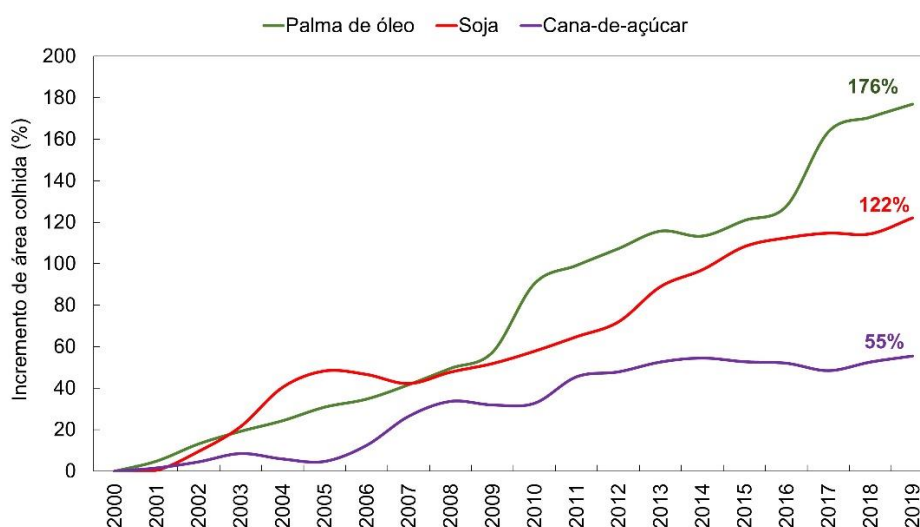


Figura 1. Principais culturas agrícolas com expansão de área colhida em porcentagem nos países tropicais úmidos.

Fonte. (FAO, 2021).

Sua inserção na cadeia do Biodiesel no Brasil foi incentivada pelo Programa Palma de Óleo, como cultura viável e rentável na recuperação de áreas em vias de degradação (Brandão et al., 2021, Garrett et al., 2019). A palma de óleo é extremamente versátil, sendo aproveitado óleos da semente, do mesocarpo e o óleo de palmiste (Awalludin et al., 2015; Mushtaq; Abdullah; Ani, 2015). Aproveitam-se ainda cachos, resíduos do processo de extração de óleo (glicerina), entre outros usos, além do seu potencial na produção de combustíveis alternativos e bioeletrecidade (Pirker et al., 2016).

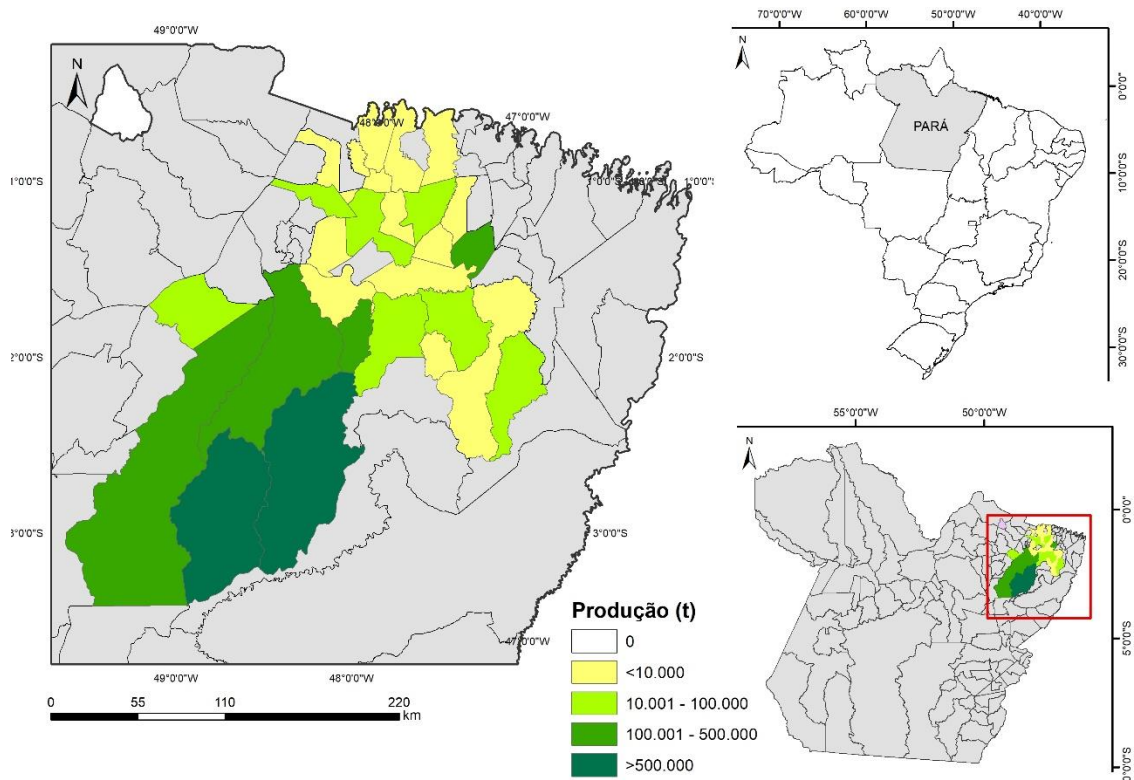


Figura 2. Mapa das principais áreas produtoras de palma de óleo no estado do Pará.

Fonte. (IBGE, 2021).

As evidências de aquecimento global, oscilações nos preços do petróleo e mudanças para uma matriz energética renovável incluem a palma de óleo como planta com alto potencial para produção de biocombustíveis, impulsionando sua lucratividade (Sheil et al., 2009).

O potencial dessa espécie na produção de óleo e conversão em biocombustível ganha importância em áreas com alto grau de degradação, inserindo-as ao sistema produtivo, minimizando a pressão do desmatamento, capturando carbono e mitigando emissões de gases de efeito estufa (GEE), além de promover oferta de emprego ao setor agrícola e industrial na Amazônia (Zarin et al., 2016).

1.2 Coqueiro

Outra palmeira de destaque, o coqueiro (*Cocos nucifera* L), é uma das mais importantes do mundo, cultivada em mais de 12 milhões de hectares de terras nas planícies costeiras tropicais e subtropicais (FAOSTAT, 2021). Cerca de 10 milhões de agricultores familiares são altamente dependentes do produto desta palmeira e muitos outros em áreas rurais e semi-urbanas que possuem reduzido número de áreas plantadas, contribuem para a subsistência dessas populações (Rethinam, 2006).

O coqueiro é uma palmeira de grande interesse econômico, uma vez que são utilizados todos os seus componentes: frutos, folhas, polpa, água, casca e fibras. Cada parte da planta pode produzir itens que têm valor comunitário, bem como fornecer uma gama de produtos comerciais e industriais (Nguyen et al., 2015). Esses produtos incluem aqueles com propriedades nutricionais e medicinais (Foale, 2003; Perera et al., 2009), com um núcleo maduro (endosperma sólido) que contém fibras comestíveis, proteínas, lipídios e minerais inorgânicos.

No Brasil, a principal atividade econômica envolvendo esta espécie destinam-se à produção de coco seco in natura, coco ralado, leite de coco, óleo de coco e outros derivados do coco seco e água de coco, a partir do coco verde (Benassi; Fanton; Santana, 2013).

Outros produtos derivados da fruta incluem bebidas, amêndoas frescas e leite (Lim, 2012), além de produtos refinados, como, o óleo virgem e a fibra da casca. O óleo virgem (extraído a baixa temperatura) possui propriedades antioxidantes potentes (Marina et al., 2009) e antimicrobianas (Chakraborty e Mitra, 2008) e possui potenciais ações anticancerígenas (Koschek et al., 2007).

No Brasil, o avanço do cultivo ocorre não só pela evolução em patamares produtivos, que condicionam ao país lugar de destaque entre os maiores produtores mundiais, mas também, pela expansão da área plantada, principalmente em regiões não tradicionais (Ferreira; Warwick; Siqueira, 2018).

O cultivo de coqueiro no Brasil tradicionalmente acontece na região Nordeste, mas nos últimos trinta anos as áreas estão se expandindo para outras regiões do Brasil, principalmente no Sudeste, Centro Oeste e Norte (Figura 3).

O novo contexto do mercado do açaí, tanto ao nível nacional como internacional, tem se caracterizado por uma demanda crescente e superior à oferta, o que pressiona os preços, sobretudo com o aumento das exportações (Homma; Santana, 2009). Nesse mercado a bebida é comercializada como *commodity*, onde o fator determinante é o preço, que oscila devido a sazonalidade da safra que se concentra no Pará, Amapá e Maranhão (Nogueira et al., 2005). No entanto, apresenta uma produção que ainda demanda de pesquisas que visem o melhor manejo do cultivo, assim como o conhecimento de áreas com potencial climático para sua expansão.

A distribuição espacial das espécies de palmeiras está predominantemente condicionada aos fatores ambientais limitantes (Bazzaz, 1998), tornando a biodiversidade do planeta vulnerável aos fenômenos naturais e processos resultantes das ações antrópicas sobre o ambiente.

Com a busca da expansão desses cultivos e melhor planejamento de safra, o uso de modelos de prognósticos agrometeorológicos auxilia no planejamento agrícola, identificando as condicionantes de variáveis atmosféricas que possam causar perdas de produção e buscar soluções estratégicas para tomada de decisão. No entanto, esse monitoramento prévio requer o uso de vários conjuntos de dados, não sendo uma tarefa trivial, em vez disso, consiste em várias etapas complicadas (Filippi et al., 2019). Neste sentido, o uso da inteligência artificial tem sido uma importante ferramenta de apoio a decisão no meio agrícola, podendo determinar diferentes padrões e correlações a partir de conjuntos de dados, ajudando a melhorar a eficiência no setor agrícola, como a produtividade da safra, irrigação, monitoramento de safra, entre outros (Talaviya et al., 2020).

1.4 Inteligência artificial

Na produção agrícola, existem várias metodologias e processos diferentes que requerem um consumo de energia bastante elevado (Jha et al. 2019). Ao mesmo tempo, o mercado exige produtos de saída de alta qualidade (Singh; Singh; Kaur, 2021).

Com o aumento da informação no campo, se amplia o horizonte de aplicabilidade e uso de modelos matemáticos. Dados históricos de clima e dados meteorológicos durante a estação de crescimento, bem como a previsão de curto, médio e longo prazo, desempenham papel importante nas aplicações de modelagem agrícola (Hogenboom, 2000).

A demanda por informações rápidas e consistentes impõe que pesquisadores, consultores, agricultores e gestores do setor agrícola ampliem as aquisições e conhecimento em modelos de simulação (Martorano, 2008). Dessa forma, as relações existentes entre os elementos climáticos e a produtividade de uma cultura podem ser simulados de forma previa antes da colheita, através de modelos agrometeorológicos (Rolim et al., 2008), usando algoritmos de Inteligência Artificial (IA) (Klompenburg; Kassahun; Catal, 2020).

A IA inicia com o estudo sobre a capacidade dos computadores de pensar sem a interferência humana (Russell; Norvig, 2011), definindo-se basicamente como uma tecnologia que funcione como o cérebro humano, que incluem aprendizagem, raciocínio e autocorreção (Parekh; Shah; Shah, 2020) para automatizar tarefas complexas (Tada, 2016). Neste conceito, softwares e sistemas inteligentes são desenvolvidos, baseados em como o cérebro humano pensa, aprende, toma decisões e trabalham enquanto resolvem um problema (Talaviya et al., 2020). Esses softwares são alimentados com dados de treinamento e, além disso, esses dispositivos inteligentes nos fornecem a saída desejada para cada entrada válida, assim como o cérebro humano (Jani et al., 2020).

A IA envolve duas grandes subáreas classificadas como, Deep learning (DL) e Machine Learning (ML) (Patel et al., 2020; Sukhadia et al., 2020). A DL é uma subárea de ML, que por sua vez é uma subárea da IA (Sharma; Sharma; Jindal, 2021) (Figura 4). Enquanto IA é a ciência de fazer máquinas e programas inteligentes, ML é a capacidade de aprender algo sem ser explicitamente programado e DL é o aprendizado por redes neurais profundas (Kodali; Sahu, 2016).

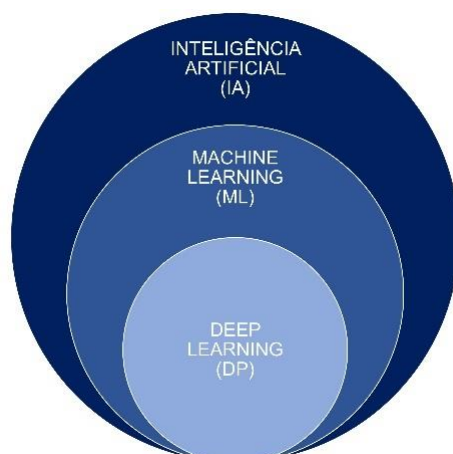


Figura 4: Inteligência artificial, Aprendizado de máquina e Aprendizagem profunda. Adaptado de Goodfellow et al. (2016).

Conforme discutido em Goodfellow et al. (2016), inicialmente o foco da inteligência artificial era enfrentar e solucionar problemas intelectualmente difíceis para os seres humanos, mas relativamente diretos para os computadores, problemas que podem ser descritos por uma lista de regras formais e matemáticas. Entretanto, observa-se que o verdadeiro desafio é resolver as tarefas fáceis para as pessoas, mas difíceis de descrever formalmente, problemas que resolvemos intuitivamente, que parecem automáticos, como reconhecer palavras ou faces nas imagens.

Para prover uma solução a esses problemas mais intuitivos é necessário que os computadores aprendam com a experiência e compreendam as informações em termos de hierarquia de conceitos, com cada conceito definido por sua relação com conceitos mais simples (Goodfellow et al., 2016), assim como o ser humano faz.

Os algoritmos de ML agrupam um grande número de métodos que permitem aos computadores generalizar a partir da experiência, aprendendo com um conjunto de dados de treinamento a reconhecer padrões em dados de alta dimensão (Bonetto; Latzko, 2020; Subasi, 2020). Em geral o ML requer um grande conjunto de dados para se treinar e prever o resultado. Entretanto, estudos recentes têm apontado o uso de ML como modelos preditivos usando pequenos conjuntos de dados (Shaikhina et al., 2015).

Patrício e Rieder (2018) definem que os processos de ML consistem basicamente nas seguintes etapas:

- Preparação e aquisição dos dados: etapa inicial que consiste em obter os dados adequados que contenham características a serem consideradas na aprendizagem.
- Seleção das características de Interesse: identificar as características mais significativas para o problema que será abordado.
- Seleção de algoritmos: consiste em selecionar o algoritmo mais adequado para tratar o problema em estudo. Como exemplo na agricultura temos a Regressão Linear Múltipla, Random Forest, Redes Neurais Artificiais, Support Vector Machine e outros.
- Seleção de parâmetros: alguns algoritmos precisam ser ajustados por parâmetros que requerem experimentação para serem definidos, dessa forma os ajustes de seus parâmetros são fundamentais para um bom desempenho do modelo.
- Treinamento: Selecionado o algoritmo mais adequado e seus parâmetros, o treinamento consiste na construção do modelo computacional que será utilizado na predição das respostas aos novos dados.
- Teste: Validação dos resultados quanto a precisão e acurácia dos dados de treinamento.

Os algoritmos de ML permitem que se analise grandes volumes de dados independentemente da complexidade, com rapidez e precisão. Vastos são as aplicações de ML na agricultura, que passam deste a modelos preditivos de safras, como observado nos trabalhos de (Pant et al., 2021; Luciano et al., 2021) na detecção de doenças (Shah et al., 2016; Chung et al., 2016), qualidade de grãos (Zareiforoush et al., 2015; Vithu; Moses, 2016), otimização de irrigação e aplicação de herbicidas (Talaviya et al., 2020) e tantas outras aplicações.

Poucos trabalhos têm investigado aplicações de modelos de IA em cultivos perenes como as palmeiras de forma geral e suas respostas produtivas em função do clima. O limitado número de trabalhos se deve principalmente ao longo período de monitoramento dessas culturas, aumentando os custos operacionais

de campo para aquisição de dados. Neste sentido, este estudo busca avaliar modelos agrometeorológicos para previsão de produtividade de palmeiras comerciais como a palma de óleo, coco e açaí na Amazônia Oriental, usando inteligência artificial.

CONCLUSÕES

Os modelos de Machine Learning (ML) quando bem treinados e testados apresentam desempenhos com RMSE médio de 0.42 t ha⁻¹ na previsão de produtividade da palma de óleo. Ao combinar o efeito em diferentes estádios fenológicos da planta com a produtividade, o modelo SVM Poly desenvolvido apresentou melhor precisão, tendência e acurácia, com antecipação de 4 meses antes da colheita.

Os prognósticos de produtividade do açaizeiro apresentam desempenho com antecedência de 6 meses em cultivo de sequeiro. Sendo que os modelos apontaram para os cultivos irrigados previsão de produtividade com 4 meses de antecipação no primeiro semestre e 7 meses no segundo semestre.

Foi possível obter modelos preditivos com a até 11 meses antes da colheita, com R² de 0,68 e MAPE de aproximadamente 11% para a previsão da produtividade de frutos de coco. A ETR_TFS, TMAX_DF(IV) e DPV_DF(II), foram as variáveis mais importantes.

A disponibilidade de variáveis agrometeorológicas e a caracterização da fenologia da cultura, possibilita a calibração de modelos robustos com rotinas baseadas em Inteligência artificial.

REFERÊNCIAS

Awalludin MF, Sulaiman O, Hashim R, Aidawati WN, Nadhari W (2015) An overview of the oil palm industry in Malaysia and its waste utilization through thermochemical conversion, specifically via liquefaction. *Renewable and Sustainable Energy Reviews*, 50: 1469 – 1484. <http://dx.doi.org/10.1016/j.rser.2015.05.085>.

Bazzaz FA (1998) Elevated CO₂ and plant production in the 21st century: can we feed billions and preserve biological diversity. In : Garab G (ed) *Photosynthesis: mechanisms and effects*, V. Kluwer Academic, Dordrecht.

Benassi AC, Fanton CJ, Santana EM (2013) *O cultivo do coqueiro-anão-verde: Tecnologias de produção*. Vitória, ES: Incaper, 120 p. il. (Incaper. Documentos, 227).

Benezoli VH, Imbuzeiro HMA, Cuadra SV, Colmanetti, MAA, Araújo, AC, Stiegler C, Motoike, SY (2021) Modeling oil palm crop for Brazilian climate conditions. *Agricultural Systems*. 190: 103130. DOI: <https://doi.org/10.1016/j.agsy.2021.103130>.

Bonetto R, Latzko V (2020) Machine learning. *Computing in Communication Networks*. <https://doi.org/10.1016/B978-0-12-820488-7.00021-9>.

Brandão F, Schoneveld G, Pacheco P, Vieira I, Piraux M, Mota D (2021) The challenge of reconciling conservation and development in the tropics: Lessons from Brazil's oil palm governance model. *World Development* 139:105268. <https://doi.org/10.1016/j.worlddev.2020.105268>.

Chakraborty M, Mitra A (2008) The antioxidant and antimicrobial properties of the methanolic extract from *Cocos nucifera* mesocarp. *Food Chem.* v. 107, p. 994–999. doi:10.1016/j.foodchem. 2007.08.083.

Chung CL, Huang KJ, Chen SY, Lai MH, Chen YC, Kuo YF (2016) Detecting Bakanae disease in rice seedlings by machine vision. *Comput. Electron. Agric.* 121, 404–411. <https://doi.org/10.1016/j.compag.2016.01.008>.

Eiserhardt WL, Svenning JC, Kissling WD, Balslev H (2011) Geographical ecology of the palms (Arecaceae): determinants of diversity and distributions across spatial scales. *Annals of Botany*, 108: 1391–1416.

FAO (2021). FAOSTAT Data: Production – Crops. Food and Agriculture Organization of the United Nations (FAO) (Accessed 07 February 2021). <http://www.fao.org/faostat/en/#data/QC>.

Ferreira JMS, Warwick DRN, Siqueira LA (2018). A cultura do coqueiro no Brasil. Embrapa, Brasília, DF, p. 508.

Filippi P, Jones EJ, Wimalathunge NS, Somarathna PDSN, Pozza LE, Ugbaje SU, Bishop TFA (2019) An approach to forecast grain crop yield using multilayered, multi-farm data sets and machine learning. *Precis. Agric.* 1–15. <https://doi.org/10.1007/s11119-018-09628-4>.

Foale M (2003) The coconut odyssey: the bounteous possibilities of the tree of life. ACIAR Monography. Canberra, v. 101.

Garrett RD, Levy S, Carlson KM, Gardner TA, Godar J, Clapp J, Villoria N (2019) Criteria for effective zero-deforestation commitments. *Global Environmental Change*, 54, 135–147. <https://doi.org/10.1016/j.gloenvcha.2018.11.003>.

Goldel B, Kissling WD, Svenning JC (2015) Geographical variation and environmental correlates of functional trait distributions in palms (Arecaceae) across the New World. *Botanical Journal of the Linnean Society*, v. 179, p. 602–617.

Goodfellow I, Bengio Y, Courville A. Deep learning. MIT press, 2016.

Homma AKO, Santana ACA (2009) agroindústria na Região Norte, In: Zibetti DW & Barroso LA (Eds.) Agroindústria: uma análise no contexto socioeconômico e jurídico brasileiro. v.1. São Paulo, LEUD. p.19-43.

Hoogenboom G (2000) Contribution of agrometeorology to the simulation of crop production and its applications. *Agricultural and Forest Meteorology*, v. 103, n. 1, p. 137–157.

IBGE (2021). Instituto Brasileiro de Geografia e Estatística. Sistema IBGE de Recuperação Automática – SIDRA. (Accessed 16 March 2021). <https://sidra.ibge.gov.br/home/pimpfbr/brasil>.

Jani K, Chaudhuri M, Patel H, Shah M (2020) Machine learning in films: an approach towards automation in film censoring. *J. of Data, Inf. and Manag.* 2, 55–64. <https://doi.org/10.1007/s42488-019-00016-9>

Jha K, Doshi A, Patel P, Shah M (2019) A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture.* 2, 1–12.

Kahn F (1997) Les palmiers de l'eldorado. Paris: Éditions de l'Oprstom. *Journal of Nutrology.* p. 252.

Klompenburg TV, Kassahun A, Catal C (2020). Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agriculture*, 177, 105709. <https://doi.org/10.1016/j.compag.2020.105709>.

Kodali RK, Sahu A (2016) An IoT based soil moisture monitoring on Losant platform. 2nd International Conference on Contemporary Computing and Informatics. IEEE. pp. 764–768.

Koschek PR, Alviano DS, Alviano CS, Gattass CR (2007) The husk fiber of *Cocos nucifera* L. (Palmae) is a source of anti-neoplastic activity. *Brazilian J Med Biol Res.* v.40, p. 1339–1343. doi:10.1590/ s0100-879x2006005000153.

Lamade E, Tcherkez G, Darlan NH, Rodrigues RL, Fresneau C, Mauve C, Lamothe-Sibold M, Sketriené D, Ghashghaie J (2016) Natural ^{13}C distribution in oil palm (*Elaeis guineensis* Jacq.) and consequences for allocation pattern. *Plant, Cell and Environment*. v. 39, p. 199–212.

Lim TK (2012) *Cocos nucifera*. In: Lim TK (ed) *Edible medicinal and non-medicinal plants*. Springer-Verlag Berlin, Berlin, p. 301–334. doi:10.1007/978-90-481-8661-7_45.

Liu Y, Heuvelink GBM, Bai Z, He P, Xu Xinpeng, Ding W, Huang S (2021) Analysis of spatio-temporal variation of crop yield in China using stepwise multiple linear regression. *Field Crops Research*, 264:108098. <https://doi.org/10.1016/j.fcr.2021.108098>.

Luciano ACS, Picoli MCA, Duft DG, Rocha JV, Leal MRLV, Maire GL (2021) Empirical model for forecasting sugarcane yield on a local scale in Brazil using Landsat imagery and random forest algorithm. *Computers and Electronics in Agriculture* 184, 106063. DOI: <https://doi.org/10.1016/j.compag.2021.106063>.

Marina AM, Man YBC, Nazimah SAH, Amin I (2009) Antioxidant capacity and phenolic acids of virgin coconut oil. *Int J Food Sci Nutr*. v. 60, p.114–123. doi:10.1080/09637480802549127.

Martins CR, Jesus Júnior LA (2014) *Produção e Comercialização de Coco no Brasil Frente ao Comércio Internacional: Panorama 2014*. 51 p. (Documentos / Embrapa Tabuleiros Costeiros,1517- 1329; 184.

Martorano LG, Faria RT, Bergamaschi H, Dalmago GA (2008) Evaluation of the COPGRO/DSSAT model performance for simulating plant growth and grain yield of soybeans, subjected to no-tillage and conventional systems in the subtropical southern Brazil. *Italian Journal of Agronomy*. 3, 795-796.

Moraes JRSC, Rolim GS, Martorano LG, Aparecido LEO, Oliveira MSP, Neto JTF (2019) Agrometeorological models to forecast açai (*Euterpe oleracea* Mart.) yield in the Eastern Amazon. *J Sci Food Agric*, 100: 1558–1569. <http://dx.doi.org/10.1002/jsfa.10164>.

Moron V, Robertson AW, Wang L (2019) Weather Within Climate: Subseasonal Predictability of Tropical Daily Rainfall Characteristics. *Sub-Seasonal to Seasonal Prediction*, p. 47-64. <https://doi.org/10.1016/B978-0-12-811714-9.00003-6>.

Mushtaq F, Abdullah TAT, Mat R, Ani FN (2015) Optimization and characterization of bio-oil produced by microwave assisted pyrolysis of oil palm shell waste biomass with microwave absorber. *Bioresour Technol*.

Nguyen QT, Bandupriya HDD, Villalobos AL, Sisunandar S, Foale M, Adkins SW (2015) Tissue culture and associated biotechnological interventions for the improvement of coconut (*Cocos nucifera* L.): a review. *Planta* v. 242, p. 1059–1076.

Nogueira OL, Figueirêdo FJC, Muller AA (2005) Açai. *Embrapa Amazônia Oriental*. Belém, Pará. *Embrapa Amazônia Oriental. (Sistemas de Produção, 4)*. p.137.

Oettli P, Behera SK, Yamagata T (2018) Climate Based Predictability of Oil Palm Tree Yield in Malaysia. *Scientific Reports*, 8:2271. doi:10.1038/s41598-018-20298-0.

Pant J, Pant RP, Singh MK, Singh DP, Pant H (2021) Analysis of agricultural crop yield prediction using statistical techniques of machine learning. *Materials Today: Proceedings*. <https://doi.org/10.1016/j.matpr.2021.01.948>.

Parekh V, Shah D, Shah M (2020) Fatigue Detection Using Artificial Intelligence Framework. *Augmented Human Research*. 5:5. <https://doi.org/10.1007/s41133-019-0023-4>.

Patel D, Shah D, Shah M (2020) The Intertwine of Brain and Body: A Quantitative Analysis on How Big Data Influences the System of Sports. *Ann. Data. Sci.* 7, 1–16. <https://doi.org/10.1007/s40745-019-00239-y>.

Pathmeswaran C, Lokupitiya E, Waidyarathne KP, Lokupitiya RS (2018). Impact of extreme weather events on coconut productivity in three climatic zones of Sri Lanka. *European Journal of Agronomy* 96, 47–53. DOI: <https://doi.org/10.1016/j.eja.2018.03.001>.

Patrício DI, Rieder R (2018) Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. *Computers and Electronics in Agriculture* 153, 69–81. DOI: <https://doi.org/10.1016/j.compag.2018.08.001>.

Perera PIP, Vidhanaarachchi VRM, Gunathilake TR, Yakandawala DMD, Hoche V, Verdeil JL, Weerakoon LK (2009) Effect of plant growth regulators on ovary culture of coconut (*Cocos nucifera* L.). *Plant Cell Tiss Org.* v. 99, p. 73–81. doi:10.1007/s11240-009-9577-z.

Pirker J, Mosnier A, Kraxner F, Havlík P, Obersteiner M (2016) What are the limits to oil palm expansion? *Global Environ. Change* 40, 73–81. <https://doi.org/10.1016/j.gloenvcha.2016.06.007>.

Rethinam P (2006) Asian and Pacific coconut community activities, achievements and future outlook. *ACIAR Proceedings Series*, v. 125, p.15–21.

Rolim GS, Ribeiro RV, Azevedo FA, Camargo MBP, Machado EC (2008) Previsão do número de frutos a partir da quantidade de estruturas reprodutivas em laranjeiras. *Revista Brasileira de Fruticultura*. 30, 48-53.

Russell SJ, Norvig P (2011) *Artificial Intelligence: A Modern Approach*, third ed. Pearson. Global Edition.

Samarasinghe CRK, Meegahakumbura MK, Dissanayaka HDMAC, Kumarathunge D, Perera L (2018) Variation in yield and yield components of different coconut cultivars in response to within year rainfall and temperature variation. *Scientia Horticulturae*, 238, 51–57. DOI: <https://doi.org/10.1016/j.scienta.2018.03.058>.

Santos MMS, Lacerda CF, Neves ALR, Sousa CHCS, Ribeiro AA, Bezerra MA, Araújo ICS, Gheyi HR (2020) Ecophysiology of the tall coconut growing under different coastal areas of northeastern Brazil. *Agricultural Water Management* 232, 106047. <https://doi.org/10.1016/j.agwat.2020.106047>.

Shah JP, Prajapati HB, Dabhi VK (2016) A survey on detection and classification of rice plant diseases. In: 2016 IEEE International Conference on Current Trends in Advanced Computing (ICCTAC), 1–8. doi:<https://doi.org/10.1109/ICCTAC.2016.7567333>.

Shaikhina T, Lowe D, Daga S, Briggs D, Hggins R, Khovanova N (2015) Machine learning for predictive modelling based on small data in biomedical engineering. *IFAC Pap Online*, 48–20:469–474. <https://doi.org/10.1016/j.ifacol.2015.10.185>.

Sharma N, Sharma R, Jindal N (2021) Machine Learning and Deep Learning Applications-A Vision. *Global Transitions Proceedings*. 2, 24-28. <https://doi.org/10.1016/j.gltp.2021.01.004>.

Sheil D, Casson A, Meijaard E, Van Noordwijk M, Gaskell J, Sunderland-Groves J, Wertz K, Kanninen M (2009) Palm Oil Impacts and Opportunities in Southeast Asia: What do we know and what do we need to know? Occasional Paper. CIFOR, Bogor, Indonésia. v. 51 p. 80.

Silva IM, Santana AC, Reis MS (2006) Análise dos retornos sociais oriundos de adoção tecnológica na cultura do açaí no Estado do Pará. *Amazônia: Ciência & Desenvolvimento*, v. 2, p. 25-37.

Singh G, Singh A, Kaur G (2021) Role of Artificial Intelligence and the Internet of Things in Agriculture. *Artificial Intelligence to Solve Pervasive Internet of Things Issues*, 317-330. <https://doi.org/10.1016/B978-0-12-818576-6.00016-2>.

Subasi A (2020) Machine learning techniques. *Practical Machine Learning for Data Analysis Using Python*, p. 91-202. <https://doi.org/10.1016/B978-0-12-821379-7.00003-5>.

Sukhadia A, Upadhyay K, Gundeti M, Shah S, Shah M (2020) Optimization of smart traffic governance system using artificial intelligence. *Augment Hum Res* 5, 13. <https://doi.org/10.1007/s41133-020-00035-x>.

Talaviya T, Shah D, Patel N, Yagnik H, Shah M (2020) Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. *Artificial Intelligence in Agriculture*, 4, 58–73. <https://doi.org/10.1016/j.aiia.2020.04.002>.

Vallejo MI, Galeano G, Bernal R, Zuidem PA (2014) The fate of populations of *Euterpe oleracea* harvested for palm heart in Colombia. *Forest Ecology and Management*. v. 318, p. 274–284.

Viana LF, Homma AKO, Menezes AJEA, Santos JC, Farias Neto JT (2020) Viabilidade econômica do cultivo de açaizeiro (*euterpe oleracea* mart.) irrigado no nordeste paraense. *International Journal of Development Research*. 10, 39177-39182. <https://doi.org/10.37118/ijdr.19655.08.2020>.

Vijay V, Pimm SL, Jenkins CN, Smith SJ (2016) The Impacts of Oil Palm on Recent Deforestation and Biodiversity Loss. *PLoS ONE*. v. 11: e0159668. [doi:10.1371/journal.pone.0159668](https://doi.org/10.1371/journal.pone.0159668).

Vithu P, Moses JÁ (2016) Machine vision system for food grain quality evaluation: A review. *Trends Food Sci. Technol.* 56, 13–20. <https://doi.org/10.1016/j.tifs.2016.07.011>.

Zareiforush H, Minaei S, Alizadeh MR, Banakar A (2015) Potential applications of computer vision in quality inspection of rice: a review. *Food Eng. Rev.* 7 (3), 321–345. <https://doi.org/10.1007/s12393-014-9101-z>.

Zarin DJ, Harris NL, Baccini A, Aksenov D, Hansen MC, Azevedo-Ramos C, Azevedo, T, Margono BA, Alencar AC, Gabris C, Allegretti A, Potapov P, Farina M, Walker WS, Shevade VS, Loboda TV, Turubanova S, Tyukavina A (2016) Can carbon emissions from tropical deforestation drop by 50% in 5 years?. *Glob Chang Biol.* v. 22, p.1336-47.