

**UNIVERSIDADE FEDERAL DO RECÔNCAVO DA BAHIA  
CENTRO DE CIÊNCIAS AGRÁRIAS, AMBIENTAIS E BIOLÓGICAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS GENÉTICOS VEGETAIS  
CURSO DE MESTRADO**

**PREDIÇÃO DA PRODUTIVIDADE DO MAMOEIRO POR  
MEIO DA INTELIGÊNCIA COMPUTACIONAL**

**Leila Verena da Conceição**

**CRUZ DAS ALMAS - BA  
2021**

# **PREDIÇÃO DA PRODUTIVIDADE DO MAMOEIRO POR MEIO DA INTELIGÊNCIA COMPUTACIONAL**

**Leila Verena da Conceição**

Licenciada em Ciências Biológicas

Universidade Federal do Recôncavo da Bahia (UFRB), 2018.

Dissertação submetida ao Colegiado de Curso do Programa de Pós-Graduação em Recursos Genéticos Vegetais da Universidade Federal do Recôncavo da Bahia e Embrapa Mandioca e Fruticultura, como requisito parcial para obtenção do Grau de Mestre em Recursos Genéticos Vegetais.

**Orientador:** Prof. Dr. Sebastião de Oliveira e Silva

**Coorientadora:** Prof. Dr.<sup>a</sup> Cristina Ferreira Nepomuceno

**Coorientador:** Prof. Dr. Bruno Vinícius Castro Guimarães

**CRUZ DAS ALMAS – BAHIA  
2021**

## FICHA CATALOGRÁFICA

C744p

Conceição, Leila Verena da.

Predição da produtividade do mamoeiro por meio da inteligência computacional / Leila Verena da Conceição. \_ Cruz das Almas, Bahia, 2021.

114f.; il.

Dissertação (Mestrado) – Universidade Federal do Recôncavo da Bahia, Centro de Ciências Agrárias, Ambientais e Biológicas, Mestrado em Recursos Genéticos Vegetais.

Orientador: Prof. Dr. Sebastião de Oliveira e Silva.

Coorientadora: Prof. Dra. Cristina Ferreira Nepomuceno.

Coorientador: Prof. Dr. Bruno Vinícius Castro Guimarães.

1.Mamão – Cultivo. 2.Mamão – Inovações tecnológicas. 3.Produtividade agrícola – Análise. I.Universidade Federal do Recôncavo da Bahia, Centro de Ciências Agrárias, Ambientais e Biológicas. II.Título.

CDD: 634.651

**UNIVERSIDADE FEDERAL DO RECÔNCAVO DA BAHIA  
CENTRO DE CIÊNCIAS AGRÁRIAS, AMBIENTAIS E BIOLÓGICAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS GENÉTICOS VEGETAIS  
CURSO DE MESTRADO**

**PREDIÇÃO DA PRODUTIVIDADE DO MAMOEIRO POR MEIO DA INTELIGÊNCIA  
COMPUTACIONAL**

Comissão Organizadora da Defesa de Dissertação  
Leila Verena da Conceição

Aprovada em 19 de agosto de 2021

Prof. Dr. Sebastião, de Oliveira e Silva  
Universidade Federal do Recôncavo da Bahia  
(Orientador)

Prof. Dr. Ricardo Franco Cunha Moreira  
Universidade Federal do Recôncavo da Bahia  
(Examinador Interno)

Dr. Maurício dos Santos da Silva  
INEMA-BA  
(Examinador Externo)

## DIDICATÓRIA

Dedico a Deus. *“Assim, quer vocês comam, quer bebam, quer façam qualquer outra coisa, façam tudo para a glória de Deus. E que assim seja”*. 1 Coríntios 10:31

A minha mãe, mulher guerreira um exemplo de bondade. É graças à sua criação que me tornei uma mulher forte, que não arreda o pé diante de qualquer obstáculo. Obrigada por me criar dessa forma, mãe! Eu te amo demais.

## **AGRADECIMENTOS**

Gratidão vai além do muito obrigada. É algo superior que não consigo expressar. Foram muitas lutas e renúncias, e também conquistas! Agradeço ao maravilhoso Deus, pela permissão de mais uma etapa vencida.

Agradeço a minha família, em especial as mulheres de minha vida. Minha mãe pelo exemplo de mulher, amor e dedicação, Martinha você é meu orgulho! A minha tia Cristina pelo incentivo e ombro amigo, minha segunda mãe. A minha avó por não desistir da família e acreditar sempre no melhor de todos. A minhas irmãs Géssica, Bruna e Alana por sempre estarem ao meu lado.

Agradeço ao meu companheiro, Danilo por pacientemente suportar esta jornada e entender as decisões tomadas ao longo do caminho. Obrigada pelo amor e compreensão!

Agradeço aos meus orientadores, Dr. Sebastião de Oliveira e Silva, Dr.<sup>a</sup> Cristina Ferreira Nepomuceno e Dr. Bruno Vinícius Castro Guimarães, por toda dedicação, paciência e ensinamentos. Agradecimento especial a Dr.<sup>a</sup> Cristina Ferreira Nepomuceno, um exemplo de profissional, uma pessoa amiga, a quem eu tive o prazer de ser orientada por seis bons anos. Obrigada Cris pelo acolhimento, e por acreditar em minha capacidade, quando nem eu mesma acreditava.

Agradeço as minhas amigas pelo constante incentivo e puxões de orelha Juliana, Lara e Karine, amigas desde sempre e para sempre, queridas amigas sei que posso contar sempre com vocês. Agradeço as amizades firmadas na UFRB durante esse percurso, Taís, Marcela e Lívia, “só Jesus na causa”, da UFRB para vida.

Agradeço à Universidade Federal do Recôncavo da Bahia (UFRB) e ao Programa de Pós-Graduação em Recursos Genéticos Vegetais pela oportunidade concedida para a realização da Pós-Graduação, e aos professores que tive o privilégio de conhecer, agradeço a todos que colaboram direta ou indiretamente para minha formação.

À Coordenação de Aperfeiçoamento de Pessoal de nível Superior (CAPES), pela concessão da bolsa. Em suma, obrigado a todos que compartilharam comigo os prazeres e as dificuldades dessa jornada. ...Gratidão!

## PREDIÇÃO DA PRODUTIVIDADE DO MAMOEIRO POR MEIO DA INTELIGÊNCIA COMPUTACIONAL

**RESUMO:** O mamoeiro (*Carica papaya* L.) é cultivado em quase todo território brasileiro, e está em destaque entre as frutíferas mais importantes no agronegócio, devido, principalmente à comercialização nacional e internacional de seus frutos, ocasionando geração de emprego e renda. Portanto este estudo teve como objetivo desenvolver modelos biomatemáticos para predição da produtividade do mamoeiro CNPMF-L78, com base nos caracteres morfoagronômicos. Foram avaliadas 352 plantas em uma área útil de 2.112 m<sup>2</sup>, com os descritores da planta e os caracteres relacionados à qualidade do fruto e rendimento. Os procedimentos para análise dos dados das características morfoagronômicas usaram a estatística descritiva (média e coeficiente de variação), análise da correlação de Pearson e modelos de regressão Linear simples e Múltipla. Os dados foram submetidos a análise por Redes Neurais artificiais, utilizando-se o software R. As avaliações fenotípicas indicaram, ampla variabilidade para as características agrônômicas, com excelente expectativa de desenvolvimento vegetativo, ganhos reprodutivos e condições sensoriais de qualidade. A altura da planta (AP6; AP12; AP18) foi determinante nas variações ocorridas sobre a altura de inserção dos primeiros frutos e precocidade e sobre a produção por planta. A análise das características vegetativas, AP6; DC6; NFC9; AP12; DC12; NFC14; AP18 e DC18 por meio de adoção da regressão Linear Múltipla ou somente com as variáveis NCT9 e NCT14 pelo emprego da regressão linear Simples, permitiram a predição da produtividade em mamoeiro com maior assertividade para fomentar o aporte aos profissionais da área, por meio do planejamento agrícola. Os melhores ajustes para a estimativa da produtividade do mamoeiro foram considerados três camadas das RNA's: entrada, intermediária e a camada de saída, testando-se a composição com um a 10 neurônios na camada intermediária a maior eficiência das redes na predição da produtividade foi ajustada. Pelo coeficiente de determinação, verificaram-se os melhores ajustes para caracteres reprodutivos  $R^2 = 0,99$ , os caracteres vegetativos proporcionaram  $R^2 = 0,54$ , enquanto que os caracteres de qualidade e rendimento viabilizou  $R^2 = 0,24$ . Previsões de produtividade para o mamoeiro CNPMF-L78 foram obtidas com alta eficiência para os caracteres reprodutivos por meio de Redes Neurais Artificiais. Portanto, este trabalho servirá como subsidio e suporte para estimar produtividade em mamoeiro CNPMF-L78, tornando-se uma ferramenta eficiente e estratégica na tomada de decisões da produção agrícola, sobretudo no que diz respeito ao planejamento de pós colheita, armazenamento e transporte.

**Palavras-chave:** *Carica papaya* L; Redes neurais artificiais; Morfoagronômicos; Rendimento agrícola

## PREDICTION OF THE PRODUCTIVITY OF THE MAMAEIRO THROUGH COMPUTATIONAL INTELLIGENCE

**ABSTRACT:** Papaya (*Carica papaya* L.) is grown in almost all-Brazilian territory, and stands out among the most important fruits in agribusiness, mainly due to the national and international commercialization of its fruits, generating employment and income. Therefore, this study aimed to develop biomathematical models for predicting the productivity of papaya CNPMF-L78, based on morpho-agronomic characters. 352 plants were evaluated in a useful area of 2,112 m<sup>2</sup>, with the plant descriptors and the characters related to fruit quality and yield. The procedures for data analysis of morpho-agronomic characteristics used descriptive statistics (mean and coefficient of variation), Pearson correlation analysis, and simple and multiple linear regression models. Artificial Neural Networks, using the software R., submitted the data to analysis. The phenotypic evaluations indicated wide variability for the agronomic characteristics, with excellent expectation of vegetative development, reproductive gains and sensory quality conditions. The plant height (AP6; AP12; AP18) was determinant in the variations that occurred on the insertion height of the first fruits and precocity and on the production per plant. The analysis of the vegetative characteristics, AP6; DC6; NFC9; AP12; DC12; NFC14; AP18 and DC18 by adopting the Multiple Linear Regression or only with the variables NCT9 and NCT14 by using the Simple Linear Regression, allowed the prediction of productivity in papaya with greater assertiveness to support professionals in the area, through agricultural planning. The best fits for the estimation of papaya yield were considered three layers of ANNs: input, intermediate, and the output layer, testing the composition with one to 10 neurons in the intermediate layer the highest efficiency of the networks in yield prediction was adjusted. From the coefficient of determination, the best fits were found for reproductive characters  $R^2 = 0.99$ , vegetative characters provided  $R^2 = 0.54$ , while quality and yield characters enabled  $R^2 = 0.24$ . Yield predictions for CNPMF-L78 papaya were obtained with high efficiency for reproductive traits using Artificial Neural Networks. Therefore, this work will serve as a subsidy and support to estimate productivity in papaya CNPMF-L78, becoming an efficient and strategic tool for decision making in agricultural production, especially with regard to post-harvest planning, storage and transportation.

**Keywords:** *Carica papaya* L; Artificial neural networks; Morph-agronomics; Crop yield



## SUMÁRIO

<b>1. INTRODUÇÃO GERAL</b> .....	18
<b>2. REFERENCIAL TEÓRICO</b> .....	23
2.1. CULTURA DO MAMOEIRO ASPECTOS BOTÂNICOS.....	23
2.2. GRUPO SOLO .....	24
2.3. PROPAGAÇÃO .....	25
2.3.1. Estaquia.....	26
2.3.2. Enxertia.....	26
2.3.3. Propagação <i>in vitro</i> .....	27
3. CORRELAÇÃO DE PEARSON (R).....	27
4. REGRESSÃO LINEAR .....	28
4.1. MODELO DE REGRESSÃO SIMPLES E MÚLTIPLA (MRLM).....	29
5. MODELOS DE PREDIÇÃO.....	30
6. REDES NEURAIS ARTIFICIAIS- RNAS .....	32
6.1. ARQUITETURA DE REDE.....	35
6.2. PERCEPTRON.....	38
6.3. RETROPROPAGAÇÃO- <i>BACKPROPAGATION</i> .....	40
6.4. REDES MULTILAYER PERCEPTRON (MLP) .....	42
6.5. FUNÇÃO DE ATIVAÇÃO .....	44
6.6. PADRÕES DE APRENDIZAGEM .....	45
6.6.1. Aprendizado Supervisionado .....	46
6.6.2. Aprendizado Não-Supervisionado .....	47
<b>REFERÊNCIAS</b> .....	49
<b>CORRELAÇÃO FENOTÍPICA ENTRE OS CARACTERES AGRONÔMICOS NO MAMOEIRO E SUAS IMPLICAÇÕES SOBRE A PRODUTIVIDADE</b> .....	59
<b>1. INTRODUÇÃO</b> .....	62
<b>2. MATERIAL E MÉTODOS</b> .....	63
2.1. IMPLANTAÇÃO E CONDUÇÃO DA CULTURA DO MAMOEIRO (LINHAGEM CNPMF-L78) .....	63
2.2. CARACTERÍSTICAS MORFOAGRONÔMICAS AVALIADAS .....	64
2.2.1. Características vegetativas.....	64
2.2.2. Caracteres reprodutivos.....	65
2.2.3. Caracteres de qualidade do fruto.....	65
2.3. ANÁLISE ESTATÍSTICA.....	66
2.4.1. Estatística descritiva .....	66

2.4.2. Análise de correlação .....	66
<b>3. RESULTADOS E DISCUSSÃO .....</b>	<b>67</b>
3.1. AVALIAÇÃO FENOTÍPICA ENTRE OS CARACTERES VEGETATIVAS DO MAMOEIRO (LINHAGEM CNPMF-L78).....	67
3.2. VARIAÇÕES FENOTÍPICAS ENTRE CARACTERÍSTICAS REPRODUTIVAS E DE RENDIMENTO .....	69
3.3. VARIAÇÃO FENOTÍPICA ENTRE AS CARACTERÍSTICAS DE QUALIDADE DO FRUTO E DE RENDIMENTO.....	71
3.4. CORRELAÇÃO PARA AS CARACTERÍSTICAS VEGETATIVAS.....	73
3.4.1. Correlação para as características produtivas e de rendimento .....	75
3.4.2. Correlação para as características de qualidade do fruto e rendimento ...	76
<b>4. CONCLUSÃO .....</b>	<b>78</b>
<b>REFERÊNCIA .....</b>	<b>80</b>
<b>MODELOS DE REGRESSÃO PARA ESTIMATIVA DA PRODUTIVIDADE DO MAMOEIRO .....</b>	<b>85</b>
<b>1. INTRODUÇÃO .....</b>	<b>88</b>
<b>2. MATERIAL E MÉTODOS .....</b>	<b>89</b>
2.1. IMPLANTAÇÃO E CONDUÇÃO DA CULTURA DO MAMOEIRO (LINHAGEM CNPMF-L78)	89
2.2. CARACTERÍSTICAS MORFOAGRONÔMICAS AVALIADAS.....	90
2.2.1. Características vegetativas.....	90
2.2.2. Caracteres reprodutivos.....	90
2.2.3. Caracteres de qualidade do fruto.....	91
2.4. MODELAGEM .....	92
2.4.1. Modelo de regressão Linear Simples para predição da produtividade do mamoeiro.....	92
2.4.2. Modelos de Regressão Múltipla.....	92
<b>3. RESULTADOS E DISCUSSÃO .....</b>	<b>93</b>
3.1. CORRELAÇÃO.....	93
3.2. REGRESSÃO LINEAR SIMPLES .....	93
3.3. REGRESSÃO LINEAR MÚLTIPLA .....	94
<b>4. CONCLUSÃO .....</b>	<b>97</b>
<b>REFERÊNCIA .....</b>	<b>98</b>

<b>PREDIÇÃO DE PRODUTIVIDADE DO MAMOEIRO (<i>Carica papaya</i> L.) POR REDES NEURAS ARTIFICIAIS</b> .....	102
<b>1. INTRODUÇÃO</b> .....	10
<b>2. MATERIAL E MÉTODOS</b> .....	11
2.1. IMPLANTAÇÃO E CONDUÇÃO DA CULTURA DO MAMOEIRO (LINHAGEM CNPMF-L78)	11
2.2. CARACTERÍSTICAS MORFOAGRONÔMICAS AVALIADAS .....	12
2.2.1. Características vegetativas .....	12
2.2.2. Caracteres reprodutivos .....	13
2.2.3. Caracteres de qualidade do fruto .....	13
2.2.4. Modelagem dos dados Redes Neurais Artificiais-RNA .....	14
<b>3. RESULTADOS E DISCUSSÃO</b> .....	16
3.1. MODELAGEM DOS DADOS DE RNA PARA A VARIÁVEIS VEGETATIVAS .....	16
3.2. MODELAGEM DOS DADOS DE RNA PARA A VARIÁVEIS REPRODUTIVAS .....	18
3.3. MODELAGEM DOS DADOS DE RNA PARA A VARIÁVEIS DE QUALIDADE E RENDIMENTO DO FRUTO .....	21
<b>4. CONCLUSÃO</b> .....	23
<b>REFERÊNCIA</b> .....	24
<b>CONSIDERAÇÕES FINAIS</b> .....	27

## 1. INTRODUÇÃO GERAL

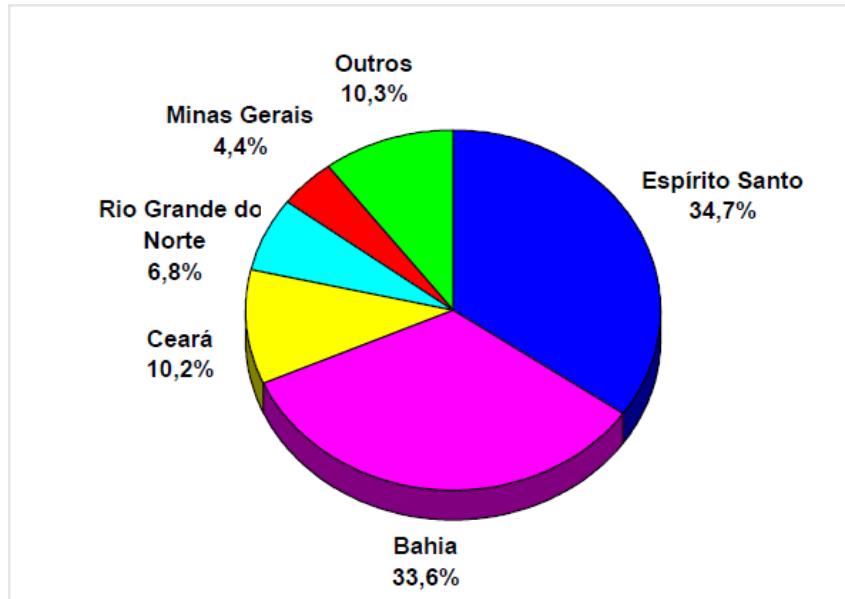
A fruticultura como ramo da agricultura é vista como as primeiras atividades socioeconômicas reconhecidas desde a Pré-História, fazendo parte da evolução no desenvolvimento da humanidade. Os precursores dessa técnica foram os povos Nômades, ao perceberem, que não precisavam mais ir em busca do alimento e sim cultivá-los próximo as suas habitações, neste contexto, surgiu o sedentarismo, propiciando o domínio dos cultivos. Fator marcante para o ser humano e a agricultura (VIEIRA et al., 2020).

Ciente da importância das sementes que se perdiam, o homem “rasgou” o solo para ajudar a natureza a preparar um leito melhor para aquela vida que germinava. Surgia assim a Agricultura, primitiva ainda, mas intensamente ligada à natureza. Além disso, era uma oportunidade mais cômoda de sobreviver (FELDENS, 2018).

A fruticultura tem grande importância econômica, social e nutricional. O mercado de frutas movimenta a economia brasileira, haja vista que a maioria é originária ou pode ser cultivada no Brasil. Segundo Crisostomo; Naumov (2009) o Brasil é um dos maiores produtores de frutas tropicais do mundo, historicamente, muitas fruteiras tropicais migraram ou dispersaram de suas regiões de origem.

Martins; Costa (2003) afirmam que, dentro da fruticultura, a cultura do mamão vem registrando, nos últimos anos, acréscimos significativos no País, tanto em área cultivada quanto na produtividade, o que também foi confirmado por Braga (2020) ao corroborar que o Brasil apesar de ser o segundo maior produtor mundial do fruto, ainda carece de melhorias que visem reduzir as perdas pós-colheita.

O mamoeiro (*Carica papaya* L.) é cultivado em quase todo território brasileiro, tornando-se o segundo maior produtor de mamão no cenário mundial (FAO, 2019), contudo, apenas cerca de 2% da produção é exportada. Em nível nacional, os estados do Espírito Santo, Bahia, Ceará e Rio Grande do Norte, são os maiores produtores desta fruta, responsáveis por cerca de 90% da produção nacional. A Bahia se destaca com a segunda maior produção no Brasil (IBGE, 2019), no entanto, ocupa o segundo lugar no ranking da exportação devido principalmente as questões fitossanitárias (Figura 1).



Fonte: IBGE - Produção Agrícola Municipal, 2019. Consultado em 27/10/2020.

**Figura 1:** Principais estados produtores de mamão no Brasil em 2019.

Além da grande importância econômica, a cultura tem grande relevância social, pois é fonte geradora de empregos e renda, uma vez que, absorve mão-de-obra durante o ano todo em função da colheita contínua e da necessidade constante de manejo. Os tratos culturais, a colheita e a comercialização são efetuadas de maneira contínua nas lavouras, além de os plantios serem renovados, em média, a cada dois ou três anos (ALMEIDA, 2006; BENASSI, 2006; LIMA et al., 2007).

No Brasil, o mamão é consumido preferencialmente in natura, normalmente quando está completamente maduro, ocasião em que apresenta a polpa macia, suculenta, com aroma adocicado e com alto conteúdo de vitaminas A e C. Um mamão de tamanho médio apresenta excedentes as recomendações nutricionais diárias (DRI) de 3000 UI para vitamina A e 90 mg para vitamina C, estabelecidas pelo U.S. Food e Nutrition and Board (PADOVANI et al., 2006).

O mamão é rico também em minerais, fibras e fonte de caroteno para a dieta diária. A industrialização, por meio do aproveitamento integral do fruto, oferece extensa gama de produtos e subprodutos, como ingrediente em geleias, sucos e doces. Além de ser uma excelente fonte da enzima papaína, que é utilizada na fabricação de cervejas, no amaciamento de carne e em certos fármacos e produtos cosméticos (SIQUEIRA, 2003; ARAVIND, 2013).

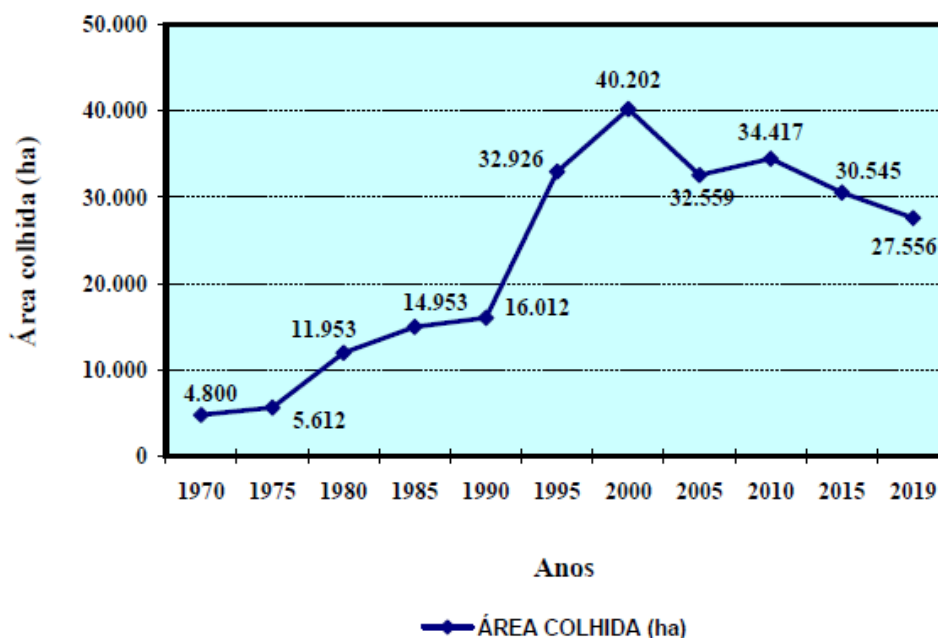
Considerada uma das fruteiras mais cultivadas nas regiões de transição tropical e subtropicais, o mamoeiro exerce grande influência no agronegócio brasileiro. A produção brasileira em 2019 foi de aproximadamente 1.161.808 toneladas (Figura 2),

ficando atrás somente da China e Índia (IBGE, 2019). Seu rendimento no período 1970-2019 foi de 42,16 t ha<sup>-1</sup>, com rendimento de até 2000 frutos ha<sup>-1</sup>. Todavia ocorreu um declínio, entre a década de 90 e o ano 2000, neste período houve queda de desempenho de colheita, obtendo melhora só no ano de 2010, culminando em queda até o ano de 2019 (Figura 3). A produção de mamão vem se destacando entre as diferentes frutas tropicais, em 2018 representou 1,5% da produção mundial de frutas, perfazendo um total aproximado de 13 milhões de toneladas, dos quais 15,4% foram produzidas na América Latina e Caribe (FAO, 2019).

Estados	Área Colhida (ha)	Produção (t)	Rendimento (t/ha)
Espírito Santo	6.874	403.278	58,67
Bahia	9.638	390.075	40,47
Ceará	1.992	118.717	59,60
Rio Grande do Norte	1.973	78.858	39,97
Minas Gerais	1.430	51.613	36,09
Outros	5.649	119.267	21,11
<b>Brasil</b>	<b>27.556</b>	<b>1.161.808</b>	<b>42,16</b>

Fonte: IBGE - Produção Agrícola Municipal, 2019. Consultado em 27/10/2020.

**Figura 2:** Desempenho da cultura do mamão no Brasil, no período 1970/2019.



Fonte: IBGE - Produção Agrícola Municipal, 2019. Consultado em 27/10/2020.

**Figura 3:** Produção brasileira de mamão em 2019.

O Brasil iniciou a exportação de mamão, na década de 90, a partir daí, houve uma crescente demanda, chegando a produzir em 2008, cerca de 1,9 milhões de toneladas, com exportação de 30 mil toneladas, atualmente o mamão está entre as sete primeiras frutas da pauta de exportação do Brasil. O Espírito Santo continua sendo o maior exportador dessa fruta, basicamente para países da União Europeia. Entretanto, menos de 1,6% do mamão brasileiro é exportado devido ao mercado internacional ser altamente competitivo, cada vez mais exigente em produtos com elevado padrão de qualidade e restritivo em relação aos problemas fitossanitários (ZANDONADI, 2020). Todavia, há uma forte propensão para ampliação das exportações do fruto brasileiro, com a implantação do sistema de produção integrada, constituído por conjunto de tecnologias que são utilizadas nas lavouras, necessárias para a certificação da produção de mamão que se destina à exportação (MARTINS; COSTA, 2003).

Estudos em tecnologias de produção têm sido realizados na área do Melhoramento Genético Vegetal a fim de potencializar a produtividade agrícola, associado a melhorias de qualidade do fruto, com o desenvolvimento de práticas que permitam reduzir de forma consistente o uso de defensivos e o custo de fertilizantes, priorizando a redução do custo de produção e com foco no aumento sustentável da produtividade média nacional do mamoeiro em 12% até o ano de 2035 (PIO et al., 2019).

A identificação de variedades de alta produtividade também é outro ponto de estudo dos programas de melhoramento. A esse respeito, Viana et al. (2015) avaliaram diferentes linhagens e híbridos de mamoeiro, e concluíram que consumidores preferem frutos de variedades que apresentam na polpa coloração vermelha, indicando, dessa forma que, além da qualidade aparente do fruto, o produtor deve estar atento a aparência e a suculência da polpa do fruto (VIANA et al., 2013).

Para que as novas tecnologias sejam implantadas na cultura do mamoeiro deve haver uma união entre produtores, empresas produtoras de sementes e órgãos de pesquisa, tais como a Embrapa Mandioca e Fruticultura (PIO et al., 2019). Dessa forma os modelos heurísticos, ou seja, a Ciência da inteligência Computacional traz uma proposta que viabiliza os dados biométricos e propõem resultados mais rápidos, com menor margem de erro. Auxiliando o agricultor e profissionais da área quanto à tomada de decisão em uma produção já prevista. No entanto, para se obter sucesso em produção agrícola, faz-se necessário o planejamento adequado, para que assim o produtor possa utilizar de ferramentas para estimar a produtividade das culturas,

sobretudo, por medidas morfométricas e não destrutivas (GUIMARÃES et al., 2013; 2018; 2019).

Vários estudos científicos têm surgido nesta perspectiva, buscando aporte nos modelos de predição pimenta (GHOLIPOOR; NADALI, 2019); frutos de *Euterpe edulis* (CANAL, 2019); maracujazeiro-amarelo (NUNES, 2020); bananeiras 'Prata-Anã' e 'BRS Platina' (GUIMARÃES et al., 2021). Estes estudos visam auxiliar o produtor em diversas culturas, tanto para planejar, como para conhecer a produtividade previamente ou até mesmo, dando base e suporte ao agricultor, isto contribuem na tomada de decisão em negociações. Todavia existem alguns aspectos a serem considerados para o desenvolvimento de modelos de previsão: a estimativa do rendimento ou de produtividade agrícola da espécie ou cultivar, o que requer dados precisos de determinação; a estimativa da área plantada, pois nada irá adiantar ter modelos de rendimento acurados, se a determinação ou estimativa da área plantada é deficiente ou vice-versa (BRAGA, 1995).

É importante considerar que cada modelo possui sua especificidade e objetivos, para tanto, cada modelo é uma ferramenta especializada na solução de determinado problema (BERNARDON; CALGARO, 2007). Ainda segundo esses autores para a solução de novos problemas são necessários novos modelos. Nessa vertente, com o advento das novas tecnologias, o desenvolvimento de tais modelos tornou-se mais fácil, aumentando a necessidade de torná-los disponíveis para pesquisadores, agricultores e profissionais da agropecuária, para o auxílio na tomada de decisão e solução de situações as quais foram criados para predizer (BRAGA, 1995). Uma vez que o principal objetivo dos empreendimentos agrícolas é obtenção da máxima lucratividade nas atividades. Em qualquer cultura, os meios de se alcançar este objetivo é a busca pelo aumento da produtividade aliada à redução dos custos de produção (CARNEIRO, 2015).

O Brasil está entre os países que produzem em grande escala juntamente com os Estados Unidos, Austrália, China e França, com o uso de ferramentas que aumentam a produtividade e reduzem os custos de manejo e que estão alicerçadas em tecnologias como a Inteligência Artificial (IA), que beneficia tanto os produtores quanto os importadores que buscam soluções para rastreabilidade de produtos, compras mais vantajosas e eficiência nas cadeias de logística (TIAGO, 2020).



Esta pesquisa teve como objetivo desenvolver modelos biomatemáticos para predição da produtividade do mamoeiro CNPMF-L78, com base nos caracteres morfoagronômicos.

## 2. REFERENCIAL TEÓRICO

### 2.1. Cultura do mamoeiro aspectos botânicos

O noroeste da América do Sul, na parte norte da bacia amazônica, é considerado como centro de origem mais provável do mamoeiro (LORENZI et al., 2006). O mamoeiro é uma angiosperma pertencente à classe Dicotyledoneae, subclasse Archichlamydeae, ordem Violales, subordem Caricineae, família Caricaceae e gênero *Carica* (COSTA; PACOVA, 2003). A família Caricaceae compreendia 31 espécies em três gêneros (*Carica*, *Jaracatia* e *Jarilla*) da América tropical e um quarto gênero, *Cylicomorpha*, da África equatorial (NAKASONE; PAUL, 1998).

No entanto, após uma revisão taxonômica, algumas espécies formalmente distribuídas no gênero *Carica* foram reclassificadas no gênero *Vasconcella*, compreendendo *Cylicomorpha* da América do Sul e América central, os cinco gêneros: *Carica*, *Jaracatia*, *Jarilla*, *Horovitzia* e *Vasconcella* e o gênero *Carica* com uma única espécie, *Carica papaya* (BADILLO, 2000).

O mamoeiro é uma planta diploide com  $2n=2x=18$  cromossomos, ou seja, possui número básico de cromossomos haploides ou genoma  $n=9$  (STOREY, 1941 ARUMUGANATHAN; EARLE, 1991). Silva; Tassara (1996) descrevem o mamoeiro como uma árvore tipicamente tropical, lactescente, herbáceo lenhoso, de caule oco, contendo grandes folhas na região apical. Apresenta sistema radicular pivotante, com ramificações radiais (DANTAS; CASTRO NETO, 2000).

Segundo Luna (1986), as raízes podem desenvolver até duas vezes à altura da planta, podendo explorar uma camada de solo com uma profundidade de até um metro. O fruto é uma baga, descrito como ovoide, esférico ou piriforme, podendo ter outras formas a depender do tipo de flor (BADILLO, 1993).

O mamoeiro apresenta três tipos de flores, as quais levam à classificação das plantas como: plantas hermafroditas, femininas e masculinas (COSTA; PACOVA, 2003). No entanto a descrição e classificação das variáveis sexuais de *C. papaya* divergem, pois são influenciadas por diferenças entre cultivares e fatores meteorológicos,

principalmente temperatura, e pelas condições de umidade do solo (DANTAS; CASTRO NETO, 2000).

Dentre as plantas do tipo Solo, destacam-se 'THB', 'Sunrise', comercialmente conhecidas como mamão papaya ou Havaí, que possuem frutos pequenos com peso médio de 0,5 kg, destinados ao mercado interno e externo. O grupo Solo ainda é composto por outras cultivares, como a *Kapoho Solo*, a *Waimanalo*, a *Higgins*, e a *Baixinho-de-Santa-Amália*, que são pouco avaliados (FARIA et al., 2009). Do grupo Formosa, o híbrido Tainung nº 01 (o mais cultivado no Brasil), o híbrido Tainung nº 2, e o híbrido Caliman 01, conhecido popularmente como Calimosa, produzem frutos de maior tamanho e peso (>1,0 kg) que é destinado, principalmente, ao mercado interno (FARIA et al., 2009; SERRANO; CATTANEO, 2010; LUZ et al., 2015).

## 2.2. Grupo Solo

A linhagem de objeto deste estudo CNPMF-L78, é proveniente de genótipos do Grupo solo, é uma linhagem desenvolvida pela Embrapa Mandioca e Fruticultura de Cruz das Almas- BA. CNPMF-L78, tem se mostrado promissora por possuir características como uniformidade de produção, frutos com bom formato e boa coloração (CARVALHO, 2015; OLIVEIRA et al., 2018).

As cultivares do Grupo Solo são linhagens puras, isto é, possuem material geneticamente uniforme, fixado por sucessivas gerações de autofecundação (DANTAS, 2000). No Brasil, teve sua inserção em meados de 1973, com o cultivo do mamão Havaí e Papaya, logo o fruto foi bem aceito pelos consumidores devido suas qualidades degustativas, o que levou a adaptação para o mercado internacional sendo encontrado em várias regiões do mundo (PICOLLO et al., 2014).

Para Dantas (2000), as principais características do Grupo Solo são de domínio de duas cultivares:

*Sunrise Solo* - Cultivar procedente da Estação Experimental do Havaí (EUA), mais conhecida no Brasil como mamão Havaí, Papaya ou Amazônia. O fruto possui peso médio de 500g, casca lisa e firme, polpa vermelho- alaranjada e cavidade interna estrelada. Começa a floração com três a quatro meses de idade, 70 cm a 80 cm de altura e sua produção tem início nove a dez meses após o plantio, produzindo em média 45 t/ha/ano. É resultado do cruzamento do mamão *Pink Solo* com a linhagem *Kariya Solo* de polpa amarela, em 1961.

*Improved Sunrise Solo Line 72/12*- Também teve sua origem do Havaí, introduzida em 1982 e melhorada pela Empresa Capixaba de Pesquisa Agropecuária (Emcapa). É conhecida como mamão Havaí, seu fruto possui casca lisa, firme, e peso médio de 500 g, de grande aceitação nos mercados interno e externo. A cavidade interna é pequena e de formato estrelado com polpa espessa e de coloração vermelho-alaranjada, todavia é mais resistente ao transporte e ao armazenamento que a *Sunrise Solo*. O início de produção ocorre a partir do oitavo mês após o plantio, quando a altura de inserção das primeiras flores atinge de 60 cm a 70 cm. A produtividade média está em torno de 40 t/ha/ano. As sementes das cultivares *Sunrise Solo* e *Improved Sunrise Solo Line 72/12*, podem ser obtidas no país, em produtores idôneos, registrados no Ministério da Agricultura e do Abastecimento. Por serem linhagens puras, estas cultivares também podem ser obtidas diretamente na propriedade rural, sem perda de suas características, desde que observados alguns princípios básicos de coleta de sementes.

### **2.3. Propagação**

O cultivo do mamoeiro requer constante renovação dos pomares (de dois anos e meio a quatro anos), o que exige tanto a produção ou a aquisição periódica de sementes quanto o preparo de mudas (FARIA et al., 2009). O mamoeiro é propagado por meio de sementes, estacas, enxertia e via biotecnológica (resgate de embriões, cultura de anteras, isolamento e cultivo de protoplastos, produção de sementes artificiais, micropropagação e transformação genética). As espécies da família *Carecaceae*, assim como as diferentes variedades comerciais de mamão são tradicionalmente propagadas por meio de sementes, ou seja, via sexuada (COSTA et al., 2019).

A propagação assexuada por meio de enraizamento de estacas e a subsequente enxertia, é uma alternativa, além da vantagem do uso de materiais com características superiores, somando as características desejáveis da planta- mãe (enxerto) e as características desejáveis do porta-enxerto (LOPEZ, 2016).

Diante do contexto a propagação vegetativa abrange diferentes formas de cultivo: estaquia, macroestaquia, miniestaquia, enxertia, cultura de tecidos via organogênese indireta, organogênese direta (ápices ou segmentos apicais) e embriogênese somática direta ou indireta (SCHMILDT, 2010).

### **2.3.1. Estaquia**

A propagação vegetativa via estaquia é uma técnica muito utilizada na floricultura, horticultura, fruticultura e silvicultura, podendo as estacas serem obtidas de caules, caules modificados (rizomas, tubérculos e bulbos), folhas ou raízes, constituindo-se em uma das formas de propagação que antecipa o período de florescimento da planta, em função da redução do seu período juvenil (SCHMILDT, 2010).

No cultivo do mamoeiro, a estaquia pode ser realizada pela coleta de brotos verdes crescidos lateralmente no tronco de plantas pré-selecionadas, os quais passam por um processo de desinfecção, aplicação de fitorregulador e nebulização, para que ocorra o enraizamento e brotação (SCHMILDT, 2010).

Entretanto, essa técnica não vem sendo utilizada devido à dominância apical do mamoeiro, o que proporciona poucas brotações laterais e também em razão da baixa capacidade de enraizamento das estacas (GRANA JR, 2000).

### **2.3.2. Enxertia**

A propagação por enxertia, assim como, por estaquia e micropropagação possuem a mesma finalidade destinada a manter os caracteres desejáveis. Essa técnica utiliza brotos laterais com cerca de 15 cm. Para o porta-enxerto, utiliza-se brotos com 5 cm de diâmetro, abrindo em seu caule uma fenda na qual é introduzido o enxerto que, por sua vez, é cortado em sua base no formato de cunha (COSTA et al., 2003).

Neste contexto, Ramkhelawan et al. (1999) testaram diversos métodos de enxertia para propagação do mamoeiro com porta-enxertos que provieram de plantas com 75 dias de idade, em que o método de cunha terminal foi claramente superior à borbulhia e a garfagem lateral, com índices de pegamento de 100%, 85% e 75%, respectivamente e com boa performance de crescimento no campo.

É importante considerar que, a enxertia permite a propagação de plantas que não podem ser multiplicadas por meio de outros métodos. Além disso, uma das principais vantagens obtidas pela enxertia é a manutenção das características genéticas da planta. Vale ressaltar que a enxertia permite também superar a juvenilidade (período no qual não há produção de frutos). Esse fenômeno compreende o período entre a

germinação da semente até o início da produção e, em algumas espécies, pode durar até 12 anos ou mais (FRANZON; CARPENEDO; SILVA, 2010).

### 2.3.3. Propagação *In Vitro*

A propagação vegetativa *in vitro* é também conhecida como micropropagação em virtude do reduzido tamanho dos propágulos utilizados, em que as plantas podem ser regeneradas via organogênese ou embriogênese somática partindo de uma célula ou tecido. Essas vias podem ocorrer direta ou indiretamente, esta última é caracterizada pela formação da fase de calo (ANDRADE, 2002).

Na organogênese ocorre a diferenciação de brotações e raízes durante o desenvolvimento vegetal. A embriogênese somática envolve o desenvolvimento de embriões a partir de células somáticas embriologicamente competente *in vitro* (PERES, 2002). Uma particularidade dos embriões somáticos é a presença de um sistema vascular fechado sem conexão vascular com os tecidos do explante inicial. Esta característica, aliada à bipolaridade diferem os embriões somáticos dos propágulos resultantes do processo de organogênese (ANDRADE, 2006).

## 3. CORRELAÇÃO DE PEARSON (r)

GARSON (2009) afirma que correlação, é uma medida de associação bivariada (força) do grau de relacionamento entre duas variáveis. No entanto MOORE (2007) diz que, a correlação mensura a direção e o grau da relação linear entre duas variáveis quantitativas. De tal forma pode-se dizer que o coeficiente de correlação de Pearson (r) é uma medida de associação linear entre variáveis, onde o coeficiente, normalmente representado por  $\rho$  assume apenas valores entre -1 e 1 e sua fórmula (I), é a seguinte:

$$\text{Cor}(Y, X) = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{y_i - \bar{y}}{s_y} \right) \left( \frac{x_i - \bar{x}}{s_x} \right) = \frac{\sum (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum (y_i - \bar{y})^2 \sum (x_i - \bar{x})^2}} \quad I.$$

O coeficiente de correlação de Pearson (r) varia de -1 a 1. O sinal indica direção positiva ou negativa do relacionamento e o valor sugere a força da relação entre as variáveis. Uma correlação perfeita (-1 ou 1) indica que o escore de uma variável pode ser determinado exatamente ao se saber o escore da outra. No outro oposto, uma

correlação de valor zero indica que não há relação linear entre as variáveis (ALDRICH,1995; HAIG, 2007; FIGUEIREDO FILHO; SILVA JÚNIOR, 2009; KOZAK, 2009).

Existem dois conceitos que são chaves para entender a correlação de Pearson: “associação” e “linearidade”. Onde a média da variância é compartilhada entre duas variáveis de tal forma que, essa variação seja distribuída linearmente. (FIGUEIREDO FILHO; SILVA JÚNIOR, 2009). Contudo, na prática os valores obtidos em experimentos, dificilmente correspondem ao estimado pelos autores, colocando o pesquisador a cargo de interpretar os dados obtidos.

Os autores COHEN (1988) e DANCEY E REIDY (2006), versaram sobre a interpretação dos escores, proporcionando e dividindo os escores como pequenos, médios e grandes, ou fraco, moderado e forte, respectivamente. Podendo assim, serem interpretados da seguinte forma, quanto mais próximo do escore 1 independente do sinal, haverá maior proximidade ou maior relação entre as variáveis. Ao passo que quanto mais próximo do escore zero, menor a proximidade ou relação entre as variáveis. Graficamente para uma correlação linear ser positiva é necessário que o escore esteja acima da média de X e Y, FIGUEIREDO FILHO; SILVA JÚNIOR, (2009).

#### **4. REGRESSÃO LINEAR**

De acordo Pandovani (2014) a origem do termo regressão deve-se a Sir Francis Galton (1822-1911) inglês de classe alta que estudou medicina em Cambridge, por volta de 1885, quando estava investigando relações antropométricas de sucessivas gerações, no estudo se debruçou na seguinte questão: qual é a relação entre as gerações e as alturas das pessoas ou se a altura era apenas hereditária. Pandovani (2014) ainda afirma que, os fenômenos biológicos, quase que na plenitude das situações, podem ser explicados por meio de modelos matemáticos.

Área da Estatística que lida com métodos para investigação da existência de associações entre várias quantidades observáveis e, se presente, a natureza das associações (GRAYBILL; IYER, 1994). Para Chatterjee; Hadi (2006) regressão linear é um método simples para investigação de relacionamentos funcionais entre variáveis. Também pode ser entendida como uma previsão, ao considerar valores de uma variável dependente com bases em resultados da variável independente.

Um modelo utilizado para estudar a relação funcional entre duas variáveis consiste na função linear simples ( $Y = a + bx$ ). Onde segundo CHEIN (2019), o ponto central é encontrar valores para  $a$  e  $b$ , ou seja, estimar a inclinação da reta utilizando uma amostra aleatória de dados de  $x$  e  $y$ . A inclinação nos fornece o efeito em  $y$  da mudança de uma unidade em  $x$ .

O modelo de regressão utilizado para relacionar a variável de resposta ao conjunto de variáveis preditoras pode ser determinado pelo número de variáveis preditoras através do modelo de Regressão Simples e Múltipla (MOURA; JR, 2014). Ainda segundo os autores a análise de regressão é vista como um processo iterativo, onde as saídas são utilizadas para diagnosticar, validar, criticar, e possivelmente modificar as entradas.

#### **4.1. Modelo de Regressão Simples e Múltipla (MRLM).**

O Modelo de Regressão Linear Simples é dado pelas considerações que segue:  $Y = \beta_0 + \beta_1x + E_i$ , onde:  $X$  é a variável explicativa ou independente medida sem erro, o vetor  $E$ , a variável aleatória residual na qual se procura incluir todas as influencias no comportamento da variável  $y$ , que não podem ser explicadas linearmente pelo comportamento da variável  $X$ .  $\beta_0$  e  $\beta_1$  são padrões a se estimar ou seja, o padrão desconhecido e  $Y$ , a variável explicada ou dependente (MONTGOMERY, 2001).

Na regressão linear múltipla assume-se que existe uma relação linear entre uma variável  $y$  (variável dependente) e  $p$  variáveis independentes (preditoras),  $(X_1, X_2...X_p)$ , salientando que no caso de uma regressão múltipla, os coeficientes que acompanham as variáveis independentes são interpretados de modo diferente comparado à regressão linear simples. O modelo de regressão linear múltipla com  $p$  variáveis explicativas é definido da seguinte forma:  $y_i = \beta_0 + \beta_1x_{i1} + \beta_2x_{i2} + \dots + \beta_px_{ip} + E_i$ ,  $i = 1, \dots, n$ , em que:

- $y_i$ , representa o valor da variável resposta na observação  $i = 1, \dots, n$ ;
- $x_{i1}, x_{i2}, x_{ip}$ ,  $i = 1, \dots, n$ , são os valores da  $i$ -ésima observação das  $p$  variáveis explicativas, (constantes conhecidas);
- $\beta_0, \beta_1, \beta_2, \beta_p$  são os parâmetros ou coeficientes de regressão;
- $E_i$ ,  $i = 1, \dots, n$ , correspondem aos erros aleatórios.

Este modelo descreve um hiperplano  $p$ -dimensional referente às variáveis explicativas. Os pressupostos para o modelo de regressão linear múltipla são análogos ao do modelo de regressão linear simples (GONZÁLEZ-MANTEIGA; CAO, 1993). Assim tem-se:

- $E[E_i] = 0, i = 1, \dots, n;$
- Os erros são independentes;
- $V[E_i] = \sigma^2, i = 1, \dots, n;$  (variâncias constantes);
- Os erros têm distribuição normal.

Quando as observações em  $n$  for maior que o número de variáveis de controle, para estimar a equação de regressão e, por consequência, estimar  $y$ , utiliza-se o método de Mínimos Quadrados Ordinários (MQO), que visa minimizar as somas quadráticas dos resíduos  $E_i$ . O estimador de MQO de  $\beta$  representa a equação:  $\beta = (X'X)^{-1}X'y$  (MONTGOMERY, 2001; NETER et al., 2005).

## 5. MODELOS DE PREDIÇÃO

As técnicas de produção alicerçam-se, cada vez mais, no aperfeiçoamento do uso dos insumos (*inputs*), e nas metodologias destinadas a estimar a produção, de forma a melhorar a produtividade e a rentabilidade. Ao reconhecer que o meio ambiente interage entre si, ocasionando a produtividade das culturas agrícolas, e que o conhecimento dos processos desta relação, é fator determinante para o desenvolvimento e sucesso da cultura, a que se destina (FRIZZONE, 2005; POSSE, 2008).

O prognóstico agrometeorológico é também denominado de previsão agrícola, de produção ou safra, pois utiliza-se de dados meteorológicos do passado e atuais para prognosticar o desempenho de produção futura. Todavia as condições ambientais, tem mudando muito nas últimas décadas, a influência antrópica nos processos globais de clima, deslocamento de espécies, degradação dos solos entre outras, tem mobilizado cientistas ao redor do mundo no intuito de reconhecer e compreender a importância dos ativos da biodiversidade (JÚNIOR; PEREIRA, 2017). Portanto, é notável a importância dos modelos de predição em produtividade, como forma de driblar os efeitos da crise ambiental, visto que, não mais se pode apenas qualificar e quantificar as condições do ambiente a ser implantado determinada cultura. Faz se necessário estabelecer uma relação morfológica e fisiológica para o planejamento do potencial produtivo da cultura, que pode ser feita através da ferramenta de modelos de predição.

No ano de 1977, Baier classificou os principais tipos de modelos de predição que são: aproximação estatística ou de regressão múltipla; aproximação fisiológica e ou matemática dos processos envolvidos; simulação, com o uso de computadores e



baseada em processos fisiológicos e aproximações feitas por meio da água disponível no solo, baseando-se em estudos de evapotranspiração real. A classificação idealizada por Baier, tem seu aporte em dados de amostragem com rendimentos das colheitas, do tempo meteorológico e dados do solo; estimativa da produção com base na curva de crescimento ou nos índices de temperatura (graus e dias); modelos de simulação de crescimento que descrevem o impacto detalhado da variabilidade meteorológica nos processos físico-biológicos; estima a produção, baseada em índices de umidade do solo durante a estação de crescimento, em regiões onde há precipitação pluviométrica (BRAGA, 1995).

Os modelos de previsão agrometeorológicos, são relacionados às etapas de desenvolvimento e maturação das culturas, assim como de rendimento das colheitas, disponibilidade de umidade do solo e reservas de água, condições de frio para os cultivos hibernais, quantificação de irrigação e disponibilidade de calor (BRAGA, 1995). E estas técnicas são fundamentadas em estatísticas de variáveis analisadas no rendimento da colheita, data de floração, maturação, entre outros, que são vistas como variável dependentes, todavia existem variáveis associadas ao clima e ao solo, como, temperatura, precipitação, índices de umidade do solo e influência atmosférica.

As predições pelos métodos como Mínimos Quadrados Parciais (*Partial Least Squares*) e Regressão Linear Múltipla (*Multiple Linear Regression*) geralmente são aplicados, em situações onde variáveis de processo apresentam elevados níveis de correlação, ruído, observações faltantes e oscilações na proporção de variáveis e observações (HELFER et al., 2019). Todavia, o desempenho vegetativo e produtivo da maior parte das frutíferas, incluindo o mamoeiro *Carica papaya L.* são ponderados pelo crescimento em altura, diâmetro do caule, área foliar, número de folhas, comprimento da raiz principal e distribuição do sistema radicular no sentido horizontal e vertical no perfil do solo (ARAÚJO et al., 2005).

Contudo, a formação do fruto também é afetada pelas condições climáticas. Daí a necessidade em se obter um modelo adequado para predição na cultura do mamoeiro. O que pode ser feito de forma precoce, com os frutos ainda verdes na planta, obtendo a observação do número de frutos e, o peso médio do fruto, a produtividade poderá ser estimada para um período de até 150 dias após a contagem realizada, segundo o estudo de POSSE et al. (2007). O estudo realizado por esses autores objetivou quantificar o tempo de permanência dos frutos na planta, produzidos no verão, desde sua formação até a colheita, e analisar as estimativas de produtividade em função da

contagem dos frutos aos 180, 210 e 270 dias. Todavia, este estudo para estimar a produtividade demandou cerca de 13 meses com quatro meses de colheita, até ficar pronto.

A demanda de tempo é de suma importância para o produtor, haja vista a necessidade de se obter um suporte confiável com menor demanda de tempo e economizando mão de obra. Portanto, expansão de modelos de predição baseados em caracteres morfológicos utilizando Redes Neurais Artificiais – RNAs, podem otimizar o tempo nas avaliações, além do planejamento dos recursos que serão utilizados (Guimarães et al., 2021).

Pelo o já exposto em relação a importância da cultura do mamoeiro, seu alto valor econômico e necessidade dos produtores e compradores, a estimativa de produção e colheita será importante para possíveis negociações e previsão da produção em nível de campo, o que facilitará o manejo de forma mais precisa e também o acompanhamento da produção da cultura.

Devido a relevância e necessidade de se conhecer a produtividade previamente, diversas culturas já desenvolveram modelos preditores da produtividade, como a cultura do milho (Soares et al., 2015), da soja na região do Matopiba (Santos, 2020), cana-de-açúcar (Picoli, 2007), grãos de trigo (Mamann et al., 2016), feijoeiro (Soares et al., 2014), bananeiras cv. Tropical (Soares et al., 2014), cacau (SOUZA Jr. et al., 1999), palma forrageira (Guimarães et al., 2018), bananeiras 'Prata-Anã' e 'BRS Platina' (Guimarães et al., 2021). Todavia, o mamoeiro carece de uma ferramenta precisa, que proponha menos tempo de análise, para que o produtor tenha maior prazo para o planejamento, para assim assegurar um bom empreendimento.

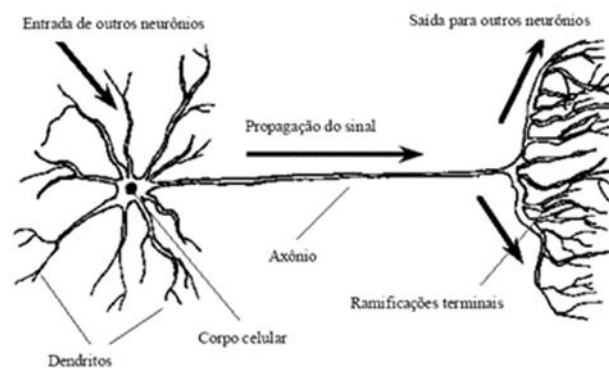
## **6. REDES NEURAIAS ARTIFICIAIS- RNAs**

A primeira conferência das RNAs a IEEE *International Conference on Neural Networks* ocorreu em São Francisco em 1987, onde também foi formada a *International Neural Networks Society* (INNS), desde então várias instituições e programas de pesquisa implementaram cursos de educação em neuro-computação. (FURTADO, 2019).

As RNAs funcionam como um modelo heurístico, capaz de realizar predições e agrupamentos em inúmeras áreas de estudo. Elas podem ser compreendidas como métodos não lineares inspirados em padrões de sinapses do cérebro humano (Figura 4).

Apesar de sua inspiração inicial, as RNAs, trabalham com processos matemáticos, fazendo a conexão em pesos, utilizando sinais de entrada e saída para cada rede, proporcionando auto aprendizado ao reconhecer padrões e formular respostas (BRAGA; CARVALHO; LUDERMIR, 2011). Para Finocchio (2011) sistemas de computação baseados em redes neurais têm a capacidade de receber ao mesmo tempo várias entradas e distribuí-las de maneira organizada.

RNAs são sistemas que mimetizam o comportamento e a estrutura do cérebro humano, todavia, possuindo um conjunto muito limitado de neurônios. Esses neurônios, por sua vez, processam paralelamente os dados e os propagam através de uma complexa malha de interconexão. Com isso, as RNAs têm a capacidade de interagir com o meio externo e adaptar-se a ele. Essas características conferem às RNAs uma importância multidisciplinar (FINOCCHIO, 2014).



Fonte: Silva (1998)

**Figura 4:** Célula neural biológica com a sequência de propagação do sinal.

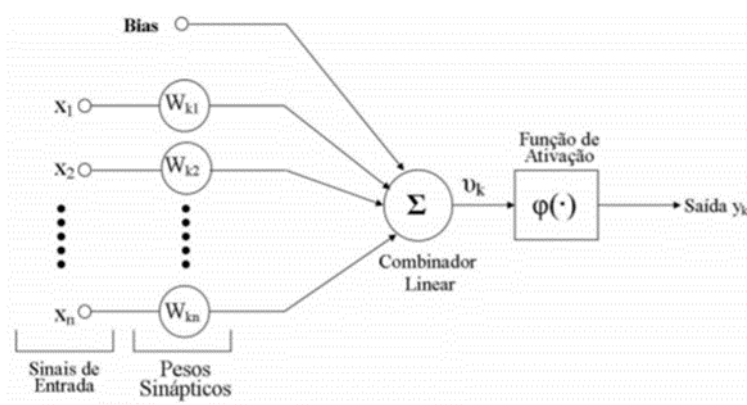
O processo de transmissão de sinais entre neurônios é fundamental para a capacidade de processamento de informação do cérebro, que ocorre quando os neurônios enviam sinais, chamados de neurônios pré-sinápticos, fazem contato com os neurônios receptores ou pós-sinápticos em regiões especializadas, denominadas de sinapses (SIQUEIRA, 2009; 2014; ZUBEN; BOCCATO, 2017).

De certa forma o neurônio pode ser visto como um dispositivo capaz de receber estímulos (de entrada) de diversos outros neurônios e propagar sua única saída, função dos estímulos recebidos e do estado interno, a vários outros neurônios. Existem diversos mecanismos envolvidos na transmissão de informação (sinais) entre neurônios (VARGAS, 2005; ZUBEN; BOCCATO, 2017). Ainda segundo ZUBEN; BOCCATO (2017) a capacidade de as sinapses sofrerem modificações, é o ingrediente-chave para o aprendizado da maioria das RNAs.

O aprendizado de uma rede reúne conhecimentos da neurociência, da computação, estatística e teoria da informação com o intuito de desenvolver modelos computacionais capazes de extrair informações importantes, que não são percebidos nos métodos convencionais (LECUN; BENGIO; HINTON, 2015).

Todavia as RNAs são compostas por elementos matemáticos denominados neurônios, que computam determinadas funções matemáticas (geralmente não-lineares). Esses neurônios são posicionados em uma ou mais camadas e interligados por conexões, geralmente unidirecionais e essas conexões estão associadas a pesos, os quais armazenam o conhecimento ponderando a entrada recebida por cada neurônio da rede (CARVALHO et al., 1998). A estrutura das RNAs é formada por diversas unidades de processamento, chamadas neurônios artificiais, que se encontram interligadas. Essa rede de neurônios artificiais se comunica através de sinais e são capazes de representar comportamentos complexos (LOUZADA, 2013).

Na visão da engenharia o modelo gráfico do neurônio McCulloch e Pitts, é interpretado da seguinte forma: os sinais de entrada  $x_j$ ; o sinal da entrada apresentado à sinapse  $j$  conectada ao neurônio  $k$  é multiplicado por um peso sináptico  $W_{kj}$ ; no neurônio  $k$ , é feita a soma ponderada dos sinais recebidos, produzindo um determinado nível de atividade. Se este nível de atividade exceder um certo limite, a unidade processadora produzirá uma determinada resposta como saída. Compreendido pelo modelo gráfico abaixo (Figura 5 e 6) e representado nos termos matemáticos, II e III (FURTADO, 2019).



Fonte: Gonçalves (2008)

**Figura 5:** Esquema do neurônio em unidade processadora de McCulloch e Pitts

II.

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j$$

$$y_k = \varphi(u_k)$$

III.

$$y_k = \varphi(u_k + b_k)$$

**Figura 6:** Neurônio artificial em termos matemáticos segundo FURTADO (2019)

Onde:  $x_j$  – sinais de entrada;  $w_{kj}$  – pesos sinápticos ou pesos;  $y_k$  sinais de saída e  $\varphi(0)$  – função de ativação. Todavia, o neurônio também pode ser excitado constantemente, e indicar o ponto em que a função de ativação se encontra no eixo elevando ou reduzindo a entrada da função de ativação, ou seja, excitado por uma polarização constante ou *bias*  $b_k$ , fato que pode ocorrer em quase todas Redes Neurais, variando com a função, causando uma modificação na equação matemática, III (LOUZADA, 2013; FURTADO, 2019).

Uma rede neural pode ser caracterizada por três aspectos principais: o padrão de conexões entre as unidades (arquitetura); o método de determinação dos pesos das conexões (algoritmo de treinamento ou aprendizado) e sua função de ativação (SILVA, 1998).


### 6.1. Arquitetura de Rede

O comportamento do sistema é controlado pela estrutura das ligações definidas pela arquitetura de rede (ou topologia), pelos valores atribuídos por cada conexão (pesos sinápticos) e a resposta de cada neurônio modulada pela função de ativação (LOUZADA, 2013). A topologia de uma rede neural diz respeito à disposição dos neurônios na rede, como são estruturados. A topologia da rede está diretamente ligada ao tipo de algoritmo de aprendizagem utilizado (GONÇALVES, 2008).

Do ponto de vista estrutural, a arquitetura de redes neurais pode ser classificada como estática, dinâmica ou *fuzzy*. Ela pode ser constituída ainda de única camada ou múltiplas camadas (FINOCCHIO, 2014). Todavia são divididas em duas classes principais: as redes alimentadas por uma única camada de neurônios e redes alimentadas diretamente com múltiplas camadas (HAYKIN, 2001). A arquitetura das RNAs é basicamente formada por três camadas. Uma camada de entrada, uma ou mais

camada intermediária, uma camada de saída. Porém, nem todas as RNAs possuem camadas intermediárias. Há três tipos principais de arquitetura em RNAs: redes *feedforward* de uma única camada; redes *feedforward* de múltiplas camadas e as redes recorrentes (SIQUEIRA, 2014). As primeiras redes de feedforward a surgirem na literatura, foram a da *Perceptron* de Rosenblatt (1962) e de *Adaline* de Widrow (1990).


Redes *feedforward*, são RNAs, que compõe apenas uma camada, suas principais aplicações são em memória associativa e no reconhecimento de padrões (Figura 7). A *Perceptron* e a *Adaline* são exemplos desse tipo de rede.



Fonte: Finocchio (2014)

**Figura 7:** Rede *feedforward* com uma camada.


Redes *feedforward* (multicamadas), possui função de reconhecer padrões e funções em seu controle (Figura 8). São exemplos deste tipo de rede: *Madaline*, *Perceptron* Multicamadas e Função Base Radial.



Fonte: Finocchio (2014)

**Figura 8:** Rede *feedforward* de múltiplas camadas.

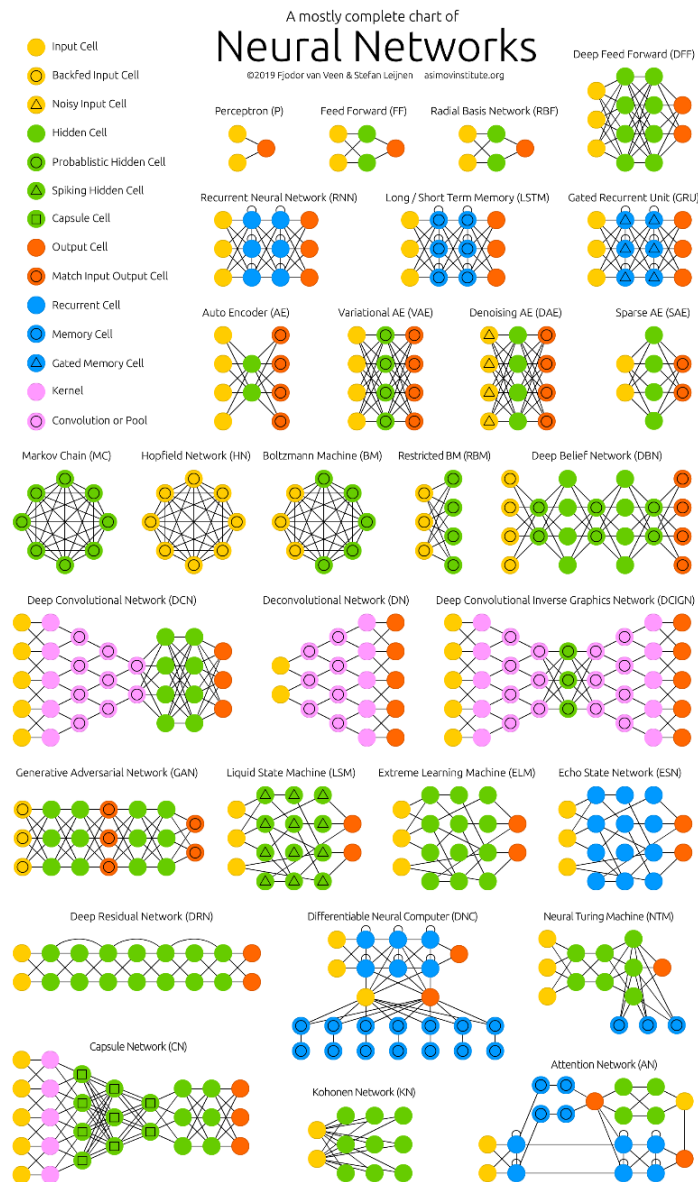
Redes recorrentes, possui aplicabilidade em sistemas dinâmicos, memória associativa, previsão e estimação, otimização e em controle, agrega também a função de realimentação entre neurônios de camadas diferentes (Figura 9). O modelo de *Hopfield* e o *Perceptron* com realimentação são exemplos desse tipo de rede (FINOCCHIO, 2014).



Fonte: Finocchio (2014)

**Figura 9:** Redes recorrentes

À medida que os estudos sobre RNAs vão se intensificando, novas arquiteturas de redes vão sendo criadas, a maioria delas são redes neurais já conhecidas, porém algumas são completamente diferentes. O *Asimov Institute*, organizou um pôster com dicas sobre as principais arquiteturas de rede (Figura 10), o qual nomeou de *The Neural Network Zoo*, embora esta lista possa fornecer alguns *insights* sobre o mundo da Inteligência Artificial, esta não é uma lista completa, pois segundo Van Veen (2019), isso seria praticamente impossível, pois novas arquiteturas são inventadas o tempo todo.



Fonte: *Asimov Institute*

**Figura 10:** The Neural Network Zoo.

## 6.2. Perceptron

Os *Perceptrons* são redes neurais que mudam com a "experiência", usando uma regra de correção de erros projetada para alterar os pesos de cada unidade de resposta quando ela dá respostas erradas a estímulos que são apresentados à rede (ARBIB, 2003). Um *perceptron* simples é aquele em que as unidades associadas não estão interconectadas, o que significa que não tem memória de curto prazo. Se tais conexões estiverem presentes, o *perceptron* é chamado de acoplamento cruzado. Um *perceptron*



de acoplamento cruzado pode ter múltiplas camadas e *loops hack* de uma camada anterior para uma posterior (ARBIB, 2003).

Um *Perceptron* multicamadas contém muitos *Perceptrons* de camada única interconectados para formar uma rede que pode implementar um sistema não linear complexo ou representar um padrão de sinal multidimensional (RUMELHART; MCCLELLAND, 1986). O cálculo aplicado ao *Perceptron* multicamadas, é realizado por meio da propagação do erro no sentido inverso, assim interpretado por Rumelhart et al. (1986), e o algoritmo é chamado de método de retropropagação do erro.

A retropropagação é uma rede de métodos utilizados para treinar uma multicamada por *Perceptron*, uma rede sem *loop* que tem suas unidades organizadas em camadas, com cada unidade fornecendo entrada apenas para unidades na próxima camada da sequência (ARBIB, 2003). A primeira camada compreende unidades de entrada; pode então haver várias camadas de unidades ocultas treináveis carregando uma representação interna e, finalmente, há a camada de unidades de saída, também com pesos sinápticos treináveis.

Sobre o estudo do procedimento de aprendizagem do *Perceptron*, Rosenblatt (1958) provou que: em um ambiente de estímulos aleatórios, um sistema que consiste em unidades conectadas aleatoriamente, sujeito às restrições paramétricas, pode aprender a associar respostas específicas a estímulos específicos.

Portanto, o objetivo do *Perceptron* é classificar corretamente o conjunto de estímulos externos aplicados,  $x_1, x_2 \dots x_m$ , em uma ou duas classes,  $C_1$  ou  $C_2$ . A regra de decisão para a classificação é atribuir o ponto representado pelas entradas,  $x_1, x_2 \dots x_m$ , à classe  $C_1$  se a saída  $y$  do *Perceptron* for (+1) e à classe  $C_2$  se for (-1) (CASTRO; CASTRO, 2001).

O ajuste dos pesos e limiar do *Perceptron* é efetuado utilizando processo de treinamento supervisionado, isto é, para cada amostra dos sinais de entrada se tem a respectiva saída (resposta) desejada. Devido às suas características estruturais, as funções de ativação normalmente usadas no *Perceptron* são a função degrau ou degrau bipolar (SILVA; SPATTI; FLAUZINO, 2016), a (Figura 11), resume os aspectos referentes ao processo de funcionamento do *Perceptron*.

Parâmetro	Variável representativa	Tipo característico
Entradas	$x_i$ ( $i$ -ésima entrada)	Reais ou binárias (advindas externamente)
Pesos sinápticos	$w_i$ (associado a $x_i$ )	Reais (iniciados aleatoriamente)
Limiar	$\theta$	Real (iniciado aleatoriamente)
Saída	$y$	Binária
Função de ativação	$g(\cdot)$	Degrau ou degrau bipolar
Processo de treinamento	-----	Supervisionado
Regra de aprendizado	-----	Regra de Hebb

Fonte: Silva; Spatti; Flauzino (2016)

**Figura 11:** Dinâmica de funcionamento do *Perceptron*.

As técnicas que normalizam as entradas consideram os limites numéricos que são exercidos pelas funções de ativação adotadas, tais técnicas propõe melhorar o desempenho computacional do processo de treinamento (SILVA; SPATTI; FLAUZINO, 2016).

### 6.3. Retropropagação- *Backpropagation*

O termo *backpropagation*, surgiu em meados do ano de 1985. Em princípio, a ideia básica foi descrita primeiro por Werbos, em seu estudo de doutorado em 1974. Em uma mesma direção foi redescoberto por Rummelhart; Hinton; Williams (1986), quando se tornou popular através do livro Processamento paralelo distribuído: explorações na microestrutura: modelos psicológicos e biológicos.

A compreensão do *backpropagation* representa um marco fundamental no desenvolvimento das redes neurais, por caracterizar um método computacionalmente eficiente para o treinamento de redes *feedforward* de múltiplas camadas (MLPs) também por extenso, além de resolver o problema de realizar a propagação reversa de erros em RNAs com múltiplas camadas, problema este que atrasou por muitos anos o desenvolvimento da área em redes neurais artificiais (CASTRO; CASTRO, 2001).

A tarefa de retropropagação é treinar um *perceptron* (ou MLP) multicamadas (*feedforward*), uma rede sem *loop* que tem suas unidades distribuídas em camadas, com uma unidade fornecendo entrada apenas para unidades na próxima camada da sequência. A primeira camada compreende entrada fixa de unidades; pode então haver

várias camadas de "unidades ocultas" treináveis carregando uma representação interna e, finalmente, há a camada de unidades de saída, também treináveis (ARBIB, 2003). É importante destacar ainda que, um *perceptron* simples corresponde ao caso em que vemos as unidades de entrada como unidades de associados fixos, ou seja, elas entregam um padrão pré-processado, em vez de um bruto, que se conecta diretamente às unidades de saída sem nenhuma unidade oculta entre elas.

É possível perceber que, cada unidade não binária, tem entrada e saída assumindo valores contínuos em alguma faixa, digamos [0, 1]. A resposta é uma função sigmoideal da soma ponderada. Assim, se uma unidade possui entradas  $X_k$  com pesos correspondentes  $W_{ik}$ , a saída  $X_i$ , é dado por  $X = \mathcal{F}_i(\sum W_{ik} X_k)$ , onde  $\mathcal{f}_i$ , é uma função sigmoideal, vejamos na equação IV (ARBIB, 2003):

$$f_i(x) = \frac{1}{1 + e^{-(x + \theta_i)}}$$

(Eq. IV)

De forma que,  $\theta_i$ , é uma tendência ou limite para a unidade. Onde o ambiente avalia apenas as unidades de saída. Recebendo um conjunto de treinamento de padrões de entrada  $p$  e padrões de destino desejados e correspondentes para as unidades de saída. Com o padrão de saída real laçado pela entrada  $p$ , o objetivo é ajustar os pesos na rede para minimizar o erro, conforme descrito no modelo V:

$$E = \sum_k (t_k - o_k)^2$$

(Eq. V)

Rumelhart; Hinton; Williams (1986) estavam entre aqueles que desenvolveram uma fórmula para propagar de volta o gradiente dessa avaliação de uma unidade para suas entradas. Este processo pode continuar por propagação de *hack* por toda a rede. O esquema parece evitar muitos mínimos erros. Em cada tentativa, é corrigido o padrão de entrada e considerado o "erro restrito" correspondente. Assim sendo (VI):

$$E = \sum_{\text{patterns } p} \sum_{\text{output neurons } k} (t_k^p - o_k^p)^2$$


(Eq. VI)

Onde  $k$  varia sobre unidades designadas, já que a rede tem muitas unidades interconectadas por pesos  $W_{ij}$ . A regra de aprendizagem é mudar  $W_{ij}$  para reduzir o gradiente descendente, conforme equação VII:

$$\Delta w_{ij} = -\frac{\partial E}{\partial w_{ij}} = 2 \sum_k (t_k - o_k) \frac{\partial o_k}{\partial w_{ij}} \quad (\text{Eq. VII})$$

#### 6.4. Redes Multilayer Perceptron (MLP)

Para driblar os percalços de maior complexidade na utilização das redes, a recomendação é a utilização das redes Multilayer Perceptron (MLP), compostas por uma ou mais camadas ocultas, nas quais os nós computacionais são chamados de neurônios ocultos ou unidades ocultas (HAYKIN, 2001). O MLP possui capacidade de aproximar qualquer tipo de função não linear contínua, limitada, diferenciável e com entradas definidas em um espaço compacto com precisão arbitrária, ou seja, é considerada uma rede de aproximação universal (CYBENKO, 1989) Uma das mais conhecidas arquiteturas de RNAs *feedforward* é o *Perceptron* de múltiplas camadas (*Multilayer Perceptron* – MLP) (Figura 12), que, estruturalmente é uma generalização do *perceptron* de Rosenblatt, treinadas com algoritmos de aprendizado por retropropagação de erro *Backpropagation*. Este modelo possibilitou a resolução de qualquer tipo de problema (LOUZADA, 2013). O seu desenvolvimento foi um dos motivos para o ressurgimento da área de redes neurais.



Fonte: Gonçalves (2017).

**Figura 12:** Rede neural artificial com arquitetura *perceptron* múltiplas camadas.

A rede MLP exhibe um alto grau de conectividade, determinado pelas sinapses da rede. Uma mudança na conectividade da rede requer uma mudança na população de conexões sinápticas, ou pesos sinápticos (CASTRO; CASTRO, 2001). Nesse sentido as redes são classificadas quanto ao grau de conectividade.

Quando cada nó (computacional ou não) em uma camada é conectado a todos os outros nós da camada adjacente dizemos ser uma rede completamente conectada. Quando as sinapses podem ser propositalmente desconectadas, objetivando minimizar a especialização do MLP (maximizar a capacidade de generalização), assim são denominadas parcialmente conectadas (FONTES, 2016).

Portanto, as sinapses podem ser desconectadas para que a conectividade de um ou mais neurônio em uma camada da rede focalize um subconjunto de todas as possíveis entradas, objetivando modularizar a arquitetura do MLP, incentivando a cooperação entre as regiões modulares assim obtidas, conclui-se que é uma rede localmente conectada, assim considerando que, uma região não afeta diretamente a outra e, assim, uma não atrapalha o processamento da outra CASTRO (2021).

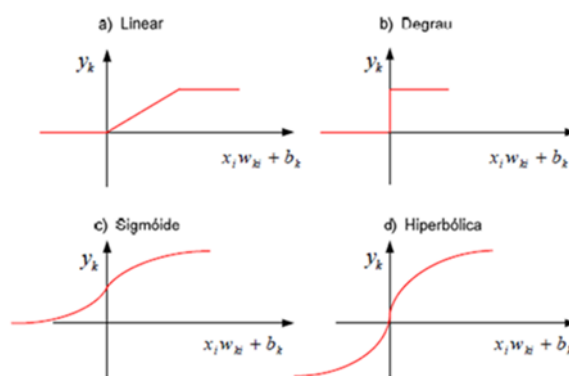
Uma rede do tipo MLP possui três características distintas: função de ativação; número de camadas e unidades intermediárias e forma das conexões (SILVA, 1998). O design e a configuração de uma rede MLP requer a consideração dos seguintes aspectos: número de nós fonte na camada de entrada, que é função da dimensionalidade do espaço de observação, que é responsável pela geração dos sinais de entrada. Número de neurônios na camada de saída, que possui função da dimensionalidade requerida da resposta desejada; número de camadas escondidas, que determinam a complexidade do modelo do MLP escolhido e não há regras determinadas para tal especificação. A função das camadas escondidas em um MLP é a de influir na relação entrada-saída da rede de uma forma ampla (FONTES, 2016).

As RNA's tipo *Multilayer Perceptron*, são as mais empregadas atualmente, por serem muito versáteis e capazes de resolver problemas desde os mais simples até os mais complexos (GONÇALVES, 2017). Numa interpretação mais superficial, uma MLP com uma ou mais camadas escondidas é apta a extrair as estatísticas de ordem superior de algum desconhecido processo aleatório subjacente, responsável pelo comportamento dos dados de entrada, processo sobre o qual a rede está tentando adquirir conhecimento, em uma perspectiva global do processo aleatório, apesar de sua conectividade local, em virtude do conjunto adicional de pesos sinápticos e da dimensão

adicional de interações neurais proporcionadas pelas camadas escondidas (FONTES, 2016).

## 6.5. Função de Ativação

A função de ativação representa o efeito que a entrada interna e o estado atual de ativação exercem na definição do próximo estado de ativação da unidade (FLECK et al., 2016). As funções de ativação mais usuais são: linear, degrau, sigmoide (ou logística) e hiperbólica (HAYKIN, 2001). A determinação da função de ativação é um dos fatores importantes para o bom funcionamento da RNA (GONÇALVES, 2008). As redes neurais que convergem dados analógicos utilizam funções com formato sigmoide como tangente hiperbólica. Já redes que processam valores direto a função deve ser do tipo degrau (Figura 13).



Fonte: Louzada (2013)

**Figura 13:** Representação gráfica das principais funções de ativação.

De tal modo que, a função linear apenas aplica um fator de multiplicação ao valor que recebe. Na camada de saída, a função de ativação linear pode ser utilizada em problemas de regressão, já que produz resultados em todo o domínio dos números reais. Contudo, essa função é limitada em sua capacidade de compreender relações mais complexas entre os dados, justamente por ser linear.

A função logística ou sigmoide produz valores no intervalo  $[0, 1]$ , possui como vantagem sua deriva que é máxima quando  $x$  está próximo de 0, o que tende a aproximar seu resultado para as extremidades do intervalo  $[0, 1]$  ao longo do treinamento. Porém essa função não é uma boa opção para ativação das camadas escondidas. Todavia, é útil para classificar probabilidades. A função tangente hiperbólica

produz resultados no intervalo  $[-1, 1]$ . Apesar de possuir as mesmas características da função sigmoide e ainda resolver um dos problemas da mesma, também possui comportamento centrado em zero. Porém, sua derivada também converge a zero, e mais rapidamente.

A principal razão pelas quais as funções de ativação são utilizadas, portanto, é para conferir essa capacidade não-linear ao processamento realizado pelas redes neurais. Isso é especialmente importante nas camadas escondidas da rede neural. Nas camadas de saída, as funções de ativação podem ter finalidades específicas, dependendo do problema que a rede neural está tentando resolver (CECCON, 2020). De acordo com os critérios de CECCON (2020), quando as funções de ativação forem aplicadas para conferir não-linearidade ao modelo deve levar em consideração:

- *Custo computacional*: em redes neurais grandes que serão treinadas por muitas épocas, o custo computacional adicional pode ter um impacto a se considerar.
- *Diferenciabilidade*: o treinamento e os ajustes, seus pesos e biases, exige que cada operação matemática realizada em cada camada tenha sua derivada calculada.
- *Centradas em zero*: capacidade de produzir iguais probabilidades de ser positivo ou negativo, através do cálculo do gradiente.
- *Não produzir platôs*: o gradiente tende a zero e a rede não é mais capaz de convergir.

## 6.6. Padrões de Aprendizagem

Em Inteligência Artificial (IA), é comum se falar de aprendizado pela máquina e aprender poder ser considerado como atributo fundamental de um comportamento inteligente. As RNAs possuem a capacidade de aprenderem, por exemplo, e, fazerem interpolações do que aprenderam (BARRETO, 2002). Designa-se à rede um conjunto de procedimentos para que a mesma possa aprender uma determinada função. Esse conjunto é chamado de algoritmo de aprendizado. Tais algoritmos se diferem pela maneira que o ajuste dos pesos é feito (PICOLI, 2007). A aprendizagem de uma rede neural é um processo onde os parâmetros livres são adaptados através de um processo de estimulação pelo ambiente em que a rede está inserida (FLECK et al., 2016). Uma das formas mais importantes de classificação se dá pela forma de aprendizagem dos

parâmetros, que pode ser supervisionada ou não supervisionada (JANG; SUN; MIZUTANI, 2012).

Um algoritmo de aprendizado é composto por um conjunto de regras bem definidas visando à solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais. Estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados (BRAGA, 2000).

A modificação ocorre com base em três eventos: I. a rede neural é estimulada por um ambiente; II. a rede neural sofre modificações nos seus parâmetros livres como resultado desta estimulação; III. a rede neural responde de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna (HAYKIN, 1999; 2001). Ou seja, a RNA extrai informações relevantes de padrões de informação apresentados a ela, dando origem a uma representação própria do problema. Nesta etapa, os parâmetros da rede são ajustados, os quais são caracterizados pelos pesos das conexões entre as unidades de processamento (FLECK et al., 2016). As principais formas de aprendizado, que estão associadas aos processos de ajuste de pesos da rede, podem ser divididas em basicamente três paradigmas aprendizado supervisionado, aprendizado não-supervisionado e aprendizado por reforço.

### 6.6.1. Aprendizado Supervisionado

É baseado em um conjunto de exemplos de estímulo/resposta (ou entrada-saída), onde a entrada e saída desejadas para a rede são fornecidas por um supervisor (Figura 14). Objetivo é adequar os parâmetros de rede, para assim, encontrar uma ligação entre os pares de entrada e saídas fornecidos. O supervisor indica claramente, um comportamento favorável ou desfavorável para a rede, com intuito de direcionar o processo de treinamento. O procedimento mais operado é a correção de erros (BRAGA, 2000; HAYKIN, 2001).





Fonte: Furtado (2019)


**Figura14:** Aprendizagem supervisionada.

Podem-se citar como exemplos de algoritmos de treinamento supervisionado, o algoritmo do Erro Médio Quadrático e a generalização do mesmo, *backpropagation*. Todavia, os modelos que mais utilizam este tipo de treinamento, são os *Perceptrons* Multicamadas e as Redes de Base Radial (FURTADO, 2019).

### 6.6.2. Aprendizado Não-Supervisionado

Baseia-se apenas nos estímulos recebidos pela rede neural. Em suma, a rede deve aprender a classificar os estímulos. Neste tipo de aprendizagem não há o supervisor. A rede ao estabelecer uma coerência com os parâmetros estatísticos da entrada de dados adquire uma habilidade de formar modelos internos para codificar padrões de entrada. Contudo, este tipo de aprendizado só se torna possível quando existe redundância nos dados de entrada (BRAGA, 2000; HAYKIN, 2001).

No treinamento não-supervisionado (Figura 15), não existe uma saída-alvo, de forma que a rede deverá adquirir a capacidade de extrair as informações relevantes dos impulsos e classificá-los em grupos pré-existentes de acordo com as respectivas semelhanças. Na hipótese, de nenhuma classe semelhante ser encontrada, a rede irá criar uma nova classe para o padrão de entrada apresentado. O ajuste dos pesos é feito de acordo com um conjunto de regras pré-estabelecidas até que se chegue a uma configuração final (FURTADO, 2019).



Fonte: Furtado (2019)

**Figura 15:** Diagrama do treinamento Não- Supervisionado.

Como exemplos de algoritmo de treinamento não-supervisionado têm-se o de Aprendizado Competitivo, assim como o modelo de Rede Neural Artificial, do qual se extrai os Mapas Auto-Organizáveis de Kohonen e os Modelos ART de Grossberg & Carpenter (HAYKIN, 2001). A aprendizagem competitiva abrange um grupo de

neurônios que são todos iguais entre si, no entanto, há um limite imposto sobre a força de cada neurônio de maneira que a resposta a um grupo de dados é estabelecida apenas com um neurônio de saída ou um neurônio do grupo que esteja ativo FURTADO (2019). O aprendizado não supervisionado também é chamado de descobridor de regularidades ou redes auto- organizadas devido à propriedade básica de seu funcionamento (BARRETO, 2002).

## REFERÊNCIAS

- ALDRICH, J. H. Correlations Genuine and Spurious in Pearson and Yule. **Statistical Science**, v.10, n.4, p.364-376, 1995.
- ALMEIDA, C. O. **Fruticultura brasileira em análise**. 2006. Disponível em: <http://www.portaldoagronegocio.com.br/conteudo>. Acesso em: 18.04.2020.
- ANDRADE, S. R. M. **Princípios da cultura de tecidos vegetais**. Planaltina: Embrapa. Cerrados, 2002. 16p. (Documentos 58, Embrapa Cerrados, ISSN 1517-5111).
- ANDRADE, W. F. D. E. **Efeito de "pulse" na organogênese de *Eucalyptus grandis* cultivado in vitro**. (Dissertação Mestrado) Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2006. 55 p.
- ARAÚJO, A.G.F.; YAMANISHI, O.K. Propagação vegetativa do mamoeiro via enxertia: influência do método de garfagem e do tipo e diâmetro do garfo. **Anais do papaya Brasil: Qualidade do mamão para o mercado interno**, 1, Incaper, p.321-323. Vitória, 2003
- ARAVIND, G.; BHOWMIK, D.; DURAIVEL, S.; HARISH, G. Traditional and medicinal uses of *Carica papaya*. **Journal of Medicinal Plants Studies**. Nova Deli, v.1; n.1 p.7-15, 2013.
- ARBIB, M. A. **The handbook of brain theory and neural networks**. MIT Press; second edition, 2003. ISBN-10: 0262511029.
- ARUMUGANATHAN, K.; EARLE, E.D. Nuclear DNA content of some important plant species. **Plant and Molecular Biology**. v.9, n.3, p.208-218, 1991.
- BADILLO, V. M. *Carica L. vs Vasconcella* St. Hill. (Caricaceae): con la rehabilitación de este último. **Ernstia**, v.10, p.74-79, 2000.
- BADILLO, V.M. Caricaceae, segundo esquema. **Revista de la Facultad de Agronomía de la Universidad Central de Venezuela**, v.43, p.1-111, 1993.
- BAJAJ, Y. P. S. (Ed.). **Somatic embryogenesis and synthetic seed I**. Biotechnology in agriculture and forestry. New York: Springer- Verlag, 1995, v.30. 472p.
- BARRETO, J. M. **Introdução as Redes Neurais Artificiais. Laboratório de Conexionismo e Ciências Cognitivas UFSC** -Departamento de Informática e de Estatística. Florianópolis – SC, 2002.
- BENASSI, A. C. **A economia do mamão**. 2006. Disponível em: <http://www.todafruta.com.br/todafruta>>. Acesso em: 05.08.2020.
- BERNARDON, T.; CALGARO, M. Modelo de Simulação do Crescimento de Plantas. **Ambiência - Revista do Setor de Ciências Agrárias e Ambientais**, Guarapuava, PR - v.3, n.2, 2007.

BRAGA, H. J. PREVISÃO AGRÍCOLA: UMA NOVA ABORDAGEM: **Uso de scanner aerotransportável e redes neurais** (tese de doutorado). Universidade Federal de Santa Catarina. Florianópolis/ Santa Catarina, 1995.

BRAGA, A. de P.; CARVALHO, A. C. P. de L. F. de; LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2. ed. Rio de Janeiro: LTC, 2011.

BRAGA, H. F. Mamão: Aspectos Econômicos, Biológicos E Potencialidades No Processamento Para Obtenção Do Néctar. IN: **ENCICLOPÉDIA BIOSFERA, Centro Científico Conhecer** - Jandaia-GO, v.17, n.31, p.140, 2020.

CARVALHO, A. C.P.L.F. A. P.; BRAGA, A de P; LUDERMIR, T.B. **Fundamentos de Redes Neurais Artificiais**, DCC/IM, COPPE/Sistemas, NCE/UFRJ, Rio de Janeiro, 1998.

CARVALHO, E. de M. L. **Novos genótipos de mamoeiro com adaptação ao recôncavo e extremo sul baiano** (Dissertação, p.116). Pós-Graduação em Recursos Genéticos Vegetais da Universidade Federal do Recôncavo da Bahia e Embrapa Mandioca e Fruticultura, Cruz das almas, BA, 2015.

CASTRO, F. C. C. de. **Multilayer Perceptron**. Curso: Engenharia de Telecomunicações. PUCRS - FENG – DEE, 2021. Acessado em 16.04.21. Disponível em: [http://www.fccdecastro.com.br/pdf/AAE\\_MLP\\_2019-I.pdf](http://www.fccdecastro.com.br/pdf/AAE_MLP_2019-I.pdf).

CASTRO, F. C. C. de; CASTRO, M. C. F. de. **Redes Neurais Artificiais**. Mestrado em Engenharia Elétrica. PUCRS - FENG – DEE, 2001. Acessado em 05.04.21. Disponível em: [http://www.fccdecastro.com.br/pdf/AAE\\_MLP\\_2019-I.pdf](http://www.fccdecastro.com.br/pdf/AAE_MLP_2019-I.pdf).

CECCON, Denny. Funções de ativação: definição, características, e quando usar cada uma. **IA Expert Academy**. Porto União (SC), 2020. Disponível em: <https://iaexpert.academy/2020/05/25/funcoes-de-ativacao-definicao-caracteristicas-e-quando-usar-cada-uma/>. Acessado em 30.03.2021.

CHATTERJEE, S.; HADI, A.S. **Regression analysis by example**. 4. ed. 408p. New York: John Wiley, 2006

CHEIN, Flávia. **Introdução aos modelos de regressão linear**: um passo inicial para compreensão da econometria como uma ferramenta de avaliação de políticas públicas. Brasília: ENAP, 2019, 76p.

COHEN, Jacob. **Statistical power analysis for the behavioral sciences**. Hillsdale, NJ, Erlbaum, 1988, 579p.

COSTA, A. F. S.; ABREU, E. F. M.; SCHMILDT, E. R.; COSTA, A. N.; SCHMILDT, O. Avanços observados na propagação do mamoeiro. **Revista Brasileira de Fruticultura**. Jaboticabal, v.41, n.5, p. (e-036), 2019.

COSTA, A.F. S. da; PACOVA, B. E. V. Caracterização De Cultivares, Estratégias E Perspectivas Do Melhoramento Genético Do Mamoeiro. IN: **A cultura do mamoeiro: tecnologias de produção**. Ed. Incaper, Vitória ES, 2003, 497p.

COSTA, A.F.S.; PACOVA, B.E.V. Botânica e Variedades. **In: COSTA, A.F.S. e COSTA, A.N. (Ed).** Tecnologias para produção de goiaba. Vitória: Incaper, p.27- 56, 2003.

CRISÓSTOMO, L. A.; NAUMOV, A. **Aduando para alta produtividade e qualidade: fruteiras tropicais do Brasil.** Fortaleza: Embrapa Agroindústria Tropical, 2009, 238p.

CRUZ, C. D. GENES - a software package for analysis in experimental statistics and quantitative genetics. **Acta Scientiarum. Agronomy**, v.35, n.3, p.271–276, 2013.

CRUZ, C. D. Genes Software – extended and integrated with the R, Matlab and Selegen. **Acta Scientiarum Agronomy**, v.38, n.4, p.547–552, 2016.

CRUZ, C.D.; CARNEIRO, P.C.S.; REGAZZI, A.J. **Modelos biométricos aplicados ao melhoramento genético** - Vol. 2, 3rd ed. Editora UFV, Viçosa, 2014.

CRUZ, C.D.; REGAZZI, A.J.; CARNEIRO, P.C.S. **Modelos biométricos aplicados ao melhoramento genético** – Vol. 1, 4th ed. Editora UFV, Viçosa, 2012.

CYBENKO, G. Approximation by Superpositions of a Sigmoidal Function, Mathematics and Control. **Signals, and Systems**, 1989.

DANCEY, C.; REIDY, J. **Estatística Sem Matemática para Psicologia: Usando SPSS para Windows.** Porto Alegre, Artmed, 2006.

DANTAS, J. L. L. Mamão Produção. **IN: Mamão. Produção: aspectos técnicos / Aldo Vilar Trindade.** Embrapa Mandioca e Fruticultura (Cruz das Almas, BA); Frutas do Brasil, 3. Brasília: Embrapa Comunicação para Transferência de Tecnologia, p.77, 2000.

DANTAS, J. L. L; JUNGHANS, D. T; LIMA, J. F. Variedades e Características da planta. **In: Mamão: o produtor pergunta, Embrapa responde** – 2 ed. – Brasília, DF: Embrapa, 2013. 170p.

DANTAS, J.L.L.; CASTRO NETO, M.T. Aspectos botânicos e fisiológicos. **In: Trindade, A.V. Mamão. Produção: aspectos técnicos.** Brasília: EMBRAPACNPMT, p.11-14, 2000.

ENGELMANN, F.; Plant cryopreservation: progress and prospects. **In Vitro Cellular Developmental Biololy** –Plant, v.40, p.427-433, 2004.

FAO. **Food and agriculture organization of the United Nations for a world without hunger.** Area harvested, yield and production in 2019/ FAOSTAT /FAO Statistics Division. Disponível em: <http://www.fao.org/faostat/en/#data/QC>. Acesso em: 08.06.2020.

FARIA, A. R. N; NORONHA, A. C. da S; OLIVEIRA, A. A. R; OLIVEIRA, A. M. G; CARDOSO, C. E. L; RITZINGER, C. H. S. P; OLIVEIRA, E. J. de; COELHO, E. F; SANTOS FILHO, H. P; CRUZ, J. L; OLIVEIRA, J. R. P; DANTAS, J. L. L; SOUZA, L. D; OLIVEIRA, M. de A; COELHO FILHO, M. A; SANCHES, N. F; MEISSNER FILHO, P. E; MEDINA, V. M; CORDEIRO, Z. J. M. A cultura do mamão. **IN: Coleção plantar, 65.** Embrapa Informação Tecnológica. 3ª ed. Revista ampliada. Brasília, DF: Embrapa Informação Tecnológica; Cruz das Almas: Embrapa Mandioca e Fruticultura Tropical, 2009.

FELDENS, L. **O homem, a agricultura e a história**. Ed. Univates, 171p. Lajeado 2018.

FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. da. Desvendando os mistérios do coeficiente de correlação de Pearson (r). **Revista Política Hoje**, Recife, v.18, n.1, p. 115-146, 2009.

FINOCCHIO, M. A. F. **Noções de Redes Neurais Artificiais**. Apostila. Universidade Tecnológica Federal do Paraná- UTFPR / Campus Cornélio Procópio, 2014, 29p.

FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. M. Redes Neurais Artificiais: Princípios Básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, Curitiba, v.1, n.13, p.47-57, 2016.

FONTES, C. M. L. C. O Uso de Redes Neurais na Caracterização Geofísica de Reservatórios. Dissertação de mestrado; Universidade Federal da Bahia. Salvador-Bahia, 2016.

FRANZON, R. C.; CARPENEDO S.; SILVA, J. C. S. **Produção de mudas: principais técnicas utilizadas na propagação de fruteiras**. Planaltina, DF: Embrapa Cerrados, p.56, 2010.

FRIZZONE, J. A.; ANDRADE JR., A. S.; de (Eds.). **Planejamento de irrigação: análise de decisão e investimento**. Brasília: EMBRAPA Informação Tecnológica, p.626, 2005.

FURTADO, M. I. V. **Redes neurais artificiais [recurso eletrônico]: uma abordagem para sala de aula**. Ponta Grossa (PR): Atena Editora, p.105, 2019.

GALTON, F. **Regression towards mediocrity in hereditary stature**. Journal of the Anthropological Institute Britain and Ireland, 15, p. 246-63, 1886. Disponível em: [www.galton.org/bib/JournalItem.aspx\\_action=view\\_id=157](http://www.galton.org/bib/JournalItem.aspx_action=view_id=157). Acesso em: 09.01. 2021.

GONÇALVES, A. R. **Redes Neurais Artificiais: Fundamentos e aplicações de técnicas de aprendizagem de máquinas**. Universidade Estadual de Londrina. Londrina, 2008, 22 p. Disponível em: [https://andrerico.github.io/files/pdfs/redes\\_neurais.pdf](https://andrerico.github.io/files/pdfs/redes_neurais.pdf). Acessado em: 15.03.2021.

GONÇALVES, S. B. **Modelagem Matemática da Produtividade do Corte Florestal Mecanizado**. Tese (Doutorado) – Universidade Federal do Espírito Santo. Jerônimo Monteiro - ES, 2017.

GONZÁLEZ-MANTEIGA, W.; CAO, R. **Testar a hipótese de um modelo linear geral usando estimativa de regressão não paramétrica**. Teste, v.2, n.1-2, p.161-188,1993.

GRAYBILL, F. A.; LYER, H. K. **Regression Analysis: Concepts and Applications**. Duxbury Press; Belmont, CA, 1994, 650 p.

GUIMARAES, B. V. C.; DONATO, S. L. R.; ASPIAZU, I.; AZEVEDO, A. M.; CARVALHO, A. J. Plot Size by the Variance Comparison Method for With -Gigante? Cactus pear. **Journal of Agricultural Science**, v.11, p.206, 2019.

GUIMARÃES, B. V. C.; DONATO, S. L. R.; AZEVEDO, A. M.; ASPIAZU, I.; SILVA JUNIOR, A. A. E. Prediction of - Gigante? Cactus pear yield by morphological characters

and artificial neural networks. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.22, p.315-319, 2018.

GUIMARÃES, B. V. C.; DONATO, S. L. R.; MAIA, V. M.; ASPIAZÚ, I.; RODRIGUES, M. G. V.; MARQUES, P. R. R. Simple and multiple linear regressions for harvest prediction of Prata type bananas. **African Journal of Agricultural Research**, v.8, p.6300-6308, 2013.

GUIMARÃES, B. V. C.; DONATO, S. L. R.; ASPIAZÚ, I.; AZEVEDO, A. M. Predição da produtividade de bananeiras 'Prata-Anã' e 'BRS Platina' por redes neurais artificiais. **Pesquisa Agropecuária Tropical**, [S. l.], v.51, p.e66008, 2021.

HAIG, Brian D. Spurious correlation, in **N. J. Salkind (ed.)**, Encyclopedia of Measurement and Statistics, Thousand Oaks, Sage, 2007.

HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman; 2ª ed., p.898, 2001.

HAYKIN, S. S. **Neural Networks: A Comprehensive Foundation**. Prentice Hall International Editions Series, 1999.

HELPER, Gilson; MARTINI, Bruno; SANTOS, Ronaldo; COSTA, Adilson; BARBOSA, J. TELLUS: um modelo computacional para a predição da fertilidade do solo na agricultura de precisão. **IN: Simpósio Brasileiro de Computação Ubíqua e Pervasiva (SBCUP)**, 11, 2019, Belém. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2019.

IBGE. **Censo agropecuário 2019**. Disponível em: [http:// www.ibge.gov.br/](http://www.ibge.gov.br/). Acesso em: 25. 08. 2020.

JANG, J.S.R.; SUN, C.T.; MIZUTANI, E. **Neuro-Fuzzy and Soft Computing – A computacional Approach to Learning and Machine Intelligence**. PHI Learning P International. 1990.

JI, B.; Y. SUN, YANG, S; WAN, J. Artificial neural networks for rice yield prediction in mountainous regions. **J. Agricultural Science**, Cambridge, v.145, n.03, p.249, 2007.

KOZAK, Marcin. What is strong correlation? **Teaching Statistics**, v.31, p.85-86, 2009.

KUTNER, M. H.; NACHTSHEIM, C. J.; NETER, J.; LI, W. **Applied linear statistical models**. 5. ed. Boston: McGraw-Hill/Irwin, 2005. 1396p.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v.521, n.7553, p.436–444, 2015.

LIMA, J. F.; PEIXOTO, C. P.; LEDO, C. A. S. **Índices fisiológicos e crescimento inicial de mamoeiro (Carica papaya L.) em casa de vegetação**. Ciência e Agrotecnologia, Lavras, v.31, n.5, p.1358-1363, 2007.

LOPEZ, Miguel Alfredo Ruiz. **Fatores ambientais e fisiológicos relacionados à propagação assexuada do mamoeiro (Carica papaya L.) e de espécies afins**. 2016. [104] f., il. Tese (Doutorado em Agronomia) —Universidade de Brasília, Brasília, 2016.

LORENZI, H.; BACHER, L.; LACERDA, M.; SARTORI, S. **Frutas brasileiras e exóticas cultivadas**. Instituto Plantarum. São Paulo, SP, p.640, 2006.

LOUZADA, D. R. **Deteção e Caracterização de Danos Estruturais Utilizando Sensores de Grating de Fibra Bragg e Redes Neurais Artificiais**. Departamento de Engenharia Mecânica Pontifícia. Tese de Doutorado. Universidade Católica do Rio de Janeiro (PUC-Rio). Rio de Janeiro, 2013,169p.

LUNA, J.V.U. Variedades de mamoeiros. Epamig, Belo Horizonte, MG. Informe **Agropecuário**, v.12, n.134, p.14-18, 1986.

LUZ, L. N. da; PEREIRA, M. G.; BARROS, F. R.; BARROS, G.; FERREGUETTI, G. A. Novos Híbridos de Mamoeiro Avaliados nas Condições de Cultivo Tradicional e no Semiárido Brasileiro. **Rev. Bras. Fruticultura- Online**.v.37, n.1, p.159-171, 2015.

MARINI, F. Artificial Neural Networks in foodstuff analyses: Trends and perspectives. A review. **Analytica Chimica Acta**, v.635, p.121-131, jan. 2009.

MARTINS, D. dos S.; COSTA, A. de F. S. da. **A cultura do mamoeiro: tecnologias de produção**. Ed. Incaper, 497 p. Vitória ES, 2003.

MATSUMOTO, K. **Cultura de células em suspensão: focalizando a bananeira**. Brasília: EMBRAPA Recursos Genéticos e Biotecnologia, 2006. 24p. (Boletim de Pesquisa, 126).

MCCULLOCH, W. S., & PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Butt. Math. Biophysics*, 1943, S, p.115-133.

MONTGOMERY, D. C.; VINING, G. G.; PECK, E. A. *Introduction to Linear Regression Analysis*. 3 ed. New York: John Wiley & Sons, 2001. 641p.

MOORE, D. S. **The Basic Practice of Statistics**. New York, Freeman, 774 p., 2007.

MOURA, C.; JR, E. S. **Análise de Regressão Tópicos Avançados em Avaliação de Desempenho**, 2014. Número de páginas Disponível em: [http://www.modcs.org/wp-content/uploads/2015/01/Analise\\_de\\_Regressao.pdf](http://www.modcs.org/wp-content/uploads/2015/01/Analise_de_Regressao.pdf). Acessado em: 15/12/ 2020.

NAKASONE, H.Y.; PAUL, R.E. Tropical fruits crop production science in horticulture. **Cab International**, p.445. New York, 1998.

OLIVEIRA, T. V.; SASAKI, F. F. C.; NEPOMUCENO, C. F.; SILVA, S. D. O. Fécula de mandioca, como revestimento, para conservação do mamão. **In Embrapa Mandioca e Fruticultura-Artigo em anais de congresso (ALICE)**. In: SIMPÓSIO DO PAPAYA BRASILEIRO, 7, 2018, Vitória. Produção e sustentabilidade hídrica. [s.l], 2018.

PADOVANI, Carlos Roberto. Delineamento de experimentos /**Cultura Acadêmica**: Universidade Estadual Paulista, Pró- Reitoria de Graduação, 128p. São Paulo, 2014.

PADOVANI, R. M.; AMAYA-FARFÁN, J.; COLUGNATI, F. A. B.; DOMENE, S. M. Á. Dietary reference intakes: application of tables in nutritional studies. **Revista de Nutrição**, Campinas, v.19, n.6, p.741-760, nov. /dez. 2006.



PERES, L. E. P. Bases fisiológicas e genéticas da regeneração de plantas in vitro. **Biociência**, v. 4, n. 25, p. 44-48, 2002.

PICOLI, M. C. A. **Estimativa da Produtividade Agrícola da Cana-de-açúcar Utilizando Agregados de Redes Neurais Artificiais**: Estudo de Caso Usina Catanduva. Dissertação de Mestrado INPE. São José dos Campos, p.93, 2007.

PICOLLO, M. P.; ALEXANDRE, R. S.; SILVA, M. B.; PINOTTI, L. M.; *Ciência e Tecnologia de Alimentos: Produção e Sustentabilidade*. Jundiaí: **Pacco Editorial**, p.396, 2014.

POSSE, R. P. **Determinação dos Coeficientes da Cultura (Kc), de Produtividade (Ky), da Área Foliar e Efeito da Lâmina de Irrigação, do Turno de Rega e da Adubação Potássica na Produtividade do Mamoeiro nas Regiões Norte e Noroeste Fluminense** (Tese de doutorado). Universidade Estadual do Norte Fluminense Darcy Ribeiro – UENF Campos dos Goytacazes – RJ, p. 228, 2008.

POSSE, R. P.; BERNARDO, S.; SOUSA, E. F. de; PEREIRA, M.G.; MONNERAT, P. H.; POSSE, S. C. P.; GOTTARDO, R. D. Análise da Estimativa de Produtividade do Mamoeiro, em Período de Verão, na Região Norte Fluminense. **IN: Papaya Brasil, 2007**- 6p. Linhares-ES, 2007.

R CORE TEAM R: A language and environment for statistical computing. **R Foundation for Statistical Computing**. Vienna, Austria, 2013. Número de páginas URL <http://www.R-project.org/>.

RAMKHELAWAN, E.; BAKSH, N.; LAUCKNER, B. Propagation of papaya (*Carica papaya* L.) by in vivo methods in Trinidad. **Tropical Agriculture**, v.76, n.2, p.126-130, 1999.

RESENDE, M. D. V. DE. **Software Selegen-REML / BLUP  $\mu$  a useful tool for plant breeding**. *Crop Breeding and Applied Biotechnology*, v.16, n.September, p.330–339, 2016.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Reviews*, v.65p.386–408, 1958. Wiederabdruckin [AR88], 92–114.

ROSENBLATT, F. The perceptron: A theory of statistical separability in cognitive systems. Buffalo: Cornell Aeronautical Laboratory, Inc. Rep. No. VG-1196-G-1, 1958.

RUMELHART, D. E.; MCCLELLAND, J. L. **Processamento Distribuído Paralelo, Volume I. Explorações na microestrutura da cognição: fundamentos (vol. 1)**. 567. Cambridge, MA: MIT Press, 1986.

SANTOS, I. G. dos. **Seleção de caracteres complexos em alfafa por meio de inteligência computacional**. Dissertação (Mestrado em Genética e Melhoramento) - Universidade Federal de Viçosa, 91p.Viçosa. 2017.

SANTOS, V. B. dos. **Estimação e Previsão de Produtividade de Soja por Redes Neurais no Matopiba** (dissertação de mestrado). Universidade Estadual Paulista – UNESP, 70p. Campus de Jaboticabal, 2020.

SCHMILDT, Omar. **Propagação Vegetativa Do Mamoeiro: Estaquia e Cultura de Tecidos**. Evento: VI Simpósio do Papaya Brasileiro, 119 p. UENF/Campos dos Goytacazes, 2010.

SERRANO, L. A. L.; CATTANEO, L. F. O cultivo do mamoeiro no Brasil. **Revista Brasileira de Fruticultura**, v.32, n.3, p.657-959, 2010.

SILVA, G. N.; TOMAZ, R. S.; CASTRO, I. de; ANNA, S.; NASCIMENTO, M.; BHERING, L. L. Neural networks for predicting breeding values and genetic gains. **Scientia Agricola**, Piracicaba, v.71, n6, p.494–498, 2014.

SILVA, G. NUNES, M.S.C. **Redes Neurais artificiais: Novo Paradigma para a predição de valores genéticos**. Universidade Federal de Viçosa, 105p. 2013.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais: para engenharia e ciências aplicadas. 2ª edição- 431, **Artliber**. São Paulo, 2016.

SILVA, L. N. C. **Análise e síntese de estratégias de aprendizado para redes neurais artificiais**. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia Elétrica e Computação. Universidade Estadual de Campinas, 248p. Campinas, 1998.

SILVA, S.; TASSARA. H. Frutas do Brasil. **Empresa das Artes**, São Paulo/SP.230p, 1996.

SIQUEIRA, H. V. **Previsão de Séries de Vazões com Redes Neurais Artificiais e Modelos Lineares Ajustados por Algoritmos Bio- Inspirados**. Dissertação de mestrado. Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação. Campinas /SP, 156 p. 2009.

SIQUEIRA, H. V. **Redes Neurais Artificiais Aula 3 – Bases Biológicas**. Universidade Tecnológica Federal do Paraná- UTFPR, 2014. Disponível em: <file:///C:/Users/Micro/Desktop/Redes%20Neurais/RNAs/Aula%203%20-%20Bases%20Biologicas.pdf>. Acessado em: 24. 03. 2021.

SIQUEIRA, T. V. **A cultura do mamão: desempenho no período 1961-2002**. Rio de Janeiro: BNDES, setorial, n.18, p.91-148, 2003. Disponível em: <[www.bndes.gov.br/conhecimento/bnset/set1803a.pdf](http://www.bndes.gov.br/conhecimento/bnset/set1803a.pdf)> Acesso em: 28. Jan. 2021

SOARES, J.D.R.; Pasqual, M.; LACERDA, W.S.; SILVA, S.O.; DONATO, S.L.R. Comparison of techniques used in the prediction of yield in banana plants. **Scientia Horticulturae**, v.167, p.84-90, 2014.

SOARES, F. C.; RUSSI, J. L.; ROBAINA, A. D.; PEITER, M. X.; PARIZI, A. R. C. **Uso de Rede Neural Artificial para Predição da Produção na Cultura do Feijoeiro**.IN: **XLIII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2014**. Campo Grande- MS, 2014.

SOARES, F. C.; ROBAINA, A. D.; PEITER, M. X.; RUSSI, J. L. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, Santa Maria, v. online, 2015.

SOUZA JR, J. O.; MELLO, J. W. V.; ALVAREZ, V. H.; NEVES, J. C. L.V. Produtividade do Cacaueiro em Função de Características do Solo I: Características Químicas. **R. Bras. Ci. Solo**, v.23p.863-872, 1999.

STOREY, W.B. The botany and sex relationship of the papaya. **In: Papaya Production in the Hawaiian Islands**. University of Hawaii, Hawaii Agriculture Experiment Station Bulletin 87, Honolulu, p.5-22, 1941.

TIAGO, E. **Startups usam tecnologia para revolucionar o campo e mudar padrões de consumo**. Editora Globo S.A, São Paulo – SP, 2020. Número de páginas Disponível em: <https://epocanegocios.globo.com/Economia/noticia/2020/01/startups-usam-tecnologia-para-revolucionar-o-campo-e-mudar-padroes-de-consumo.html>. Acessado em: 03.05.2021.

VAN VEEN, F.; LEIJNEN, S. **The Neural Network Zoo**. 2019, Número de páginas Disponível em: <https://www.asimovinstitute.org/neural-network-zoo>. Acessado em: 05.04.2020.

VARGAS, Patrícia Amâncio. **Sistemas Computacionais Bio- Inspirados: Síntese E Aplicação Em Inteligência Computacional E Homeostase Artificial**. Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação. 192 p. Campinas – São Paulo, 2005.

VIANA, E. de S.; REIS, R.C.; JESUS, J.L. de; JUNGHANS, D.T.; SOUZA, F.V.D. Caracterização físico-química de novos híbridos de abacaxi resistentes à fusariose. **Ciência Rural**, v.43, p. 2013.

VIANA, E. S.; REIS, R. C.; SILVA, S. C. S.; NEVES, T. T.; JACIENE, L. J. Avaliação físico-química e sensorial de frutos de genótipos melhorados de mamoeiro. **Pesq. Agropec. Trop.**, Goiânia, v.45, n.3, p.297-303, jul. /set. 2015.

VIEIRA, M. S. T. C.; DORNELLES, R. J.; ARAÚJO, J. F.; OLIVEIRA, L. M. S. R. de; SANTOS, V.M. L. dos; SILVA, M. A. V. A Revolução Agrícola do Século XIX até Meados do Século XX. **IN: REIS, A. H.; ARAÚJO, J. F.; OLIVEIRA, L. M. S. R. de. (Organizadores). Agroecologia e Territorialidades: do estado da arte aos desafios do século XX**. 387p. Juazeiro – BA: UNIVASF, 2020.

WATT, M. P.; BLAKWAY, R.; TERMIGNONI, R.; JAIN, S.M. Somatic embryogenesis in *Eucalyptus grandis* e *E. dunnii*. **In: JAIN, S. M.; GUPTA, P. K.; NEWTON, R. J. (Ed.). Somatic embryogenesis in woody plants**, Dordrecht: Kluwer Academic Publishers, v.5. P.63-78, 1999.

WERBOS, P. J. **Beyond regression: new tools for prediction and analysis in the behavioral sciences**. Thesis (Master), Harvard University, Harvard, 453 f, 1974.

WIDROW, B.; LEHR, M. A. **30 years of adaptive neural networks: Perceptrons, madaline, and backpropagation**, *Proceedings of The IEEE*, v.78, n.9p.1415–1442. Special Issue on Neural Networks.1990.

ZANDONADI, Fernanda. Nosso mamão ganha o mundo. **SafraES**. Espírito Santo, 2020. Disponível em: <https://www.safraes.com.br/anuario-agro-capixaba/nosso-mamao-ganha-mundo>. Acessado em: 24.03.2021.

ZUBEN, F. J. V. BOCCATO, L. Tópico 2: **Redes Neurais Artificiais: Estruturas Feedforward e Aprendizado Supervisionado**. DCA/FEEC/Unicamp, 2017. Número de páginas Disponível em: [https://www.dca.fee.unicamp.br/~lboccatotopico\\_2.1\\_IA013\\_redes\\_neurais\\_feedforward\\_supervisionado.pdf](https://www.dca.fee.unicamp.br/~lboccatotopico_2.1_IA013_redes_neurais_feedforward_supervisionado.pdf). Acessado em: 24.03.2021.

## **ARTIGO I**

### **CORRELAÇÃO FENOTÍPICA ENTRE OS CARACTERES AGRONÔMICOS NO MAMOEIRO E SUAS IMPLICAÇÕES SOBRE A PRODUTIVIDADE**

## **CORRELAÇÃO FENOTÍPICA ENTRE OS CARACTERES AGRONÔMICOS NO MAMOEIRO E SUAS IMPLICAÇÕES SOBRE A PRODUTIVIDADE**

**RESUMO:** Com propósito de contribuir com o fomento as pesquisas e suporte aos programas de melhoramento com o mamoeiro, objetivou-se neste estudo avaliar a relação agronômica entre as características vegetativas, reprodutivas e sensoriais do mamoeiro da Linhagem CNPMF-L78, grupo Solo, além de identificar as características morfoagronômicas com maior potencial para estimar a produtividade. Foram avaliadas 17 caracteres morfoagronômicos em 352 plantas em uma área útil de 2.112 m<sup>2</sup>. Os procedimentos para análise dos dados das características morfoagronômicas usaram a estatística descritiva (média e coeficiente de variação) e análise da correlação de Pearson. Estes procedimentos foram executados por meio do software R. Foi possível identificar estimativas com alta significância entre altura da planta, diâmetro do caule, número de frutos comerciais, número de frutos comerciais totais com a produtividade. As avaliações fenotípicas indicaram ampla variabilidade para as características agronômicas, com excelente expectativa de desenvolvimento vegetativo, ganhos reprodutivos e condições sensoriais e de qualidade. A altura da planta (AP6; AP12; AP18) foi determinante nas variações ocorridas sobre a altura de inserção dos primeiros frutos e precocidade e sobre a produção por planta.

**Palavras-chave:** Associação; *Carica papaya* L.; Descritores fenotípicos; Estimativa

## PHENOTYPIC CORRELATION BETWEEN AGRONOMIC TRAITS IN PAPAYA AND THEIR IMPLICATIONS ON PRODUCTIVITY

**ABSTRACT:** In order to contribute to the promotion of research and support for improvement programs with papaya, the objective of this study was to evaluate the agronomic relationship between the vegetative, reproductive and sensory characteristics of papaya Line CNPMF-L78, Solo group, and to identify the morph agronomic characteristics with the greatest potential for estimating productivity. Seventeen morpho-agronomic characters were evaluated in 352 plants in a useful area of 2,112 m<sup>2</sup>. The procedures for data analysis of morpho-agronomic characteristics used descriptive statistics (mean and coefficient of variation) and Pearson's correlation analysis. These procedures were performed using the R software. It was possible to identify estimates with high significance between plant height, stem diameter, number of commercial fruits, number of total commercial fruits with yield. The phenotypic evaluations indicated wide variability for the agronomic characteristics, with excellent expectation of vegetative development, reproductive gains and sensory and quality conditions. The plant height (AP6; AP12; AP18) was determinant in the variations that occurred on the insertion height of the first fruits and precocity and on the production per plant.

**Keywords:** Association; *Carica papaya L.*; Phenotypic descriptors; Estimation

## 1. INTRODUÇÃO

O mamoeiro (*Carica papaya* L.) é cultivado em quase todo território brasileiro, e está em destaque entre as frutíferas mais importantes no agronegócio brasileiro, devido, principalmente, à comercialização nacional e internacional de seus frutos, além de possuir alta produtividade durante todo o ano, ocasionando geração de emprego e renda (BRAGA, 2020).

A produtividade do mamoeiro está associada a vários fatores e um dos mais importantes é o fator ambiental, que envolve a temperatura, a umidade relativa do ar e a disponibilidade de água (SOUZA, 2020). Por ser uma fruteira de ciclo relativamente curto, pode-se planejar a implantação da lavoura de forma que a produção inicie quando os preços de mercado estiverem em alta e, assim, obter maior número de colheitas com melhor preço (DANTAS, 2000; FERREIRA et al., 2020). As estimativas agrícolas são um importante meio para auxiliar em projeções na agricultura, especialmente no que se refere a rendimentos por associações entre as partes vegetativas e ou reprodutivas.

Estudos de correlação têm sido amplamente difundidos com o propósito de elucidar a variável de interesse em diversos contextos agrícolas e, principalmente, em busca de identificar as variáveis com maior potencial para compor os modelos de predição (CARVALHO et al., 2010); atributos do solo (DALCHIAVON, 2012); índices de vegetação espectrais (MOURA, 2013); regiões do estado (BRITO et al., 2019); caracteres agronômicos (OLIVEIRA et al., 2015; CASTRO et al., 2019; GUIMARÃES et al., 2018 e 2019).

Contudo, não há na literatura pesquisas sobre predição para a estimativa da produtividade da cultura do mamoeiro, na mesma luz deste estudo. Além disso, os modelos não podem ser generalistas, pois variam com as condições locais e devem ser gerados para cada cultura e em condições específicas, pois sofrem variações com o cultivo, com as características climáticas e as exigências do mercado consumidor.

Nesse sentido as correlações podem ser analisadas quanto a magnitude, a direção e a significância. Nogueira et al. (2012) consideraram que, quando a estimativa de correlação for positiva indica a tendência de uma variável aumentar quando a outra também aumenta, e correlações negativas indicam tendência de uma variável aumentar enquanto a outra diminui.

O conhecimento das correlações tem papel fundamental ao medir o grau de associação entre variáveis e possibilitar avaliar o quanto a alteração em uma variável



pode afetar as demais, permitindo identificar as variáveis com maior relação com a variável de interesse inferindo sobre vários aspectos: rentabilidade dos recursos empregados, condições de recuperação destes recursos e perspectivas de decisões futuras sobre o empreendimento, como expansão, retração e extinção (GARCIA; COSTA; LOSS, 2003; SILVA et al., 2016).

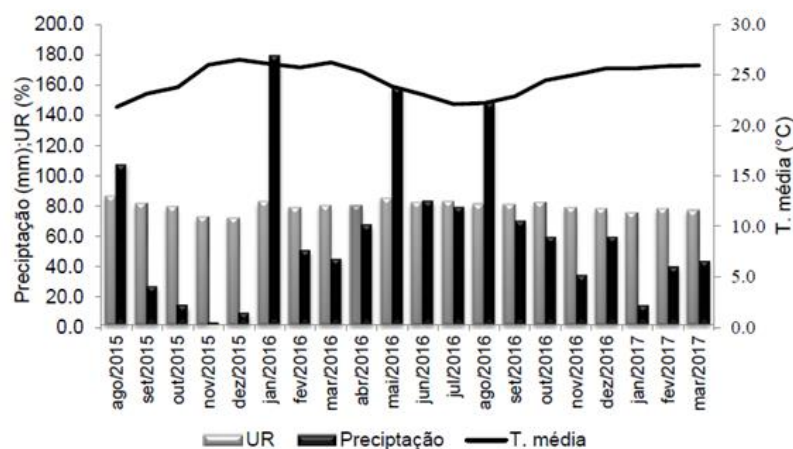
Neste contexto objetivou-se avaliar a relação agrônômica entre as características vegetativas, reprodutivas e sensoriais do mamoeiro da Linhagem CNPMF-L78, além de identificar as características morfoagrômicas com maior potencial para estimar a produtividade.

## 2. MATERIAL E MÉTODOS

### 2.1. Implantação e condução da cultura do mamoeiro (Linhagem CNPMF-L78)

O estudo foi conduzido na Embrapa Mandioca e Fruticultura, no período de agosto de 2015 a março de 2017, em Cruz das Almas (BA), situado nas coordenadas geográficas: 12°40'39" latitude sul e 39°06'23" longitude oeste de Greenwich e altitude de 226 m, com temperatura média de 24,5 °C, umidade relativa de 82% e precipitação média anual de 1.197 mm (IBGE, 2020).

As características climáticas médias registradas no período do experimento (Figuras 1) foram obtidas no Posto Meteorológico da Embrapa Mandioca e Fruticultura, localizado próximo à área experimental.



Fonte: Estação Meteorológica da Embrapa Mandioca e Fruticultura (2020).

**Figura 1.** Características climáticas médias registradas entre agosto de 2015 e março de 2017, na área experimental da Embrapa Mandioca e Fruticultura em Cruz das Almas- BA.

O solo da área experimental é do tipo Latossolo Amarelo distrófico típico (SANTOS et al., 2018), que corresponde a um Ferralsol (IUSS WORKING GROUP WRB, 2015)) ou um Oxisol (SOIL SURVEY STAFF, 2014). Para a correção e adubação do solo, seguiram-se as recomendações para a cultura do mamoeiro (OLIVEIRA; SOUZA; COELHO, 2010), sendo utilizadas na semeadura três sementes por saco plástico preenchidos com terra vegetal.

As sementes utilizadas no plantio foram da Linhagem CNPMF-L78, grupo Solo, provenientes do Banco Ativo de Germoplasma de Mamão (BAG-Mamão) da Embrapa Mandioca e Fruticultura.

Foram semeadas três sementes por saco plástico de polietileno com dimensões de 7,0 cm x 18,5 cm x 0,006 cm, correspondentes à largura, à altura e à espessura, respectivamente. Preenchidos com substrato composto por solo, areia e esterco de curral curtido, na proporção de 3:1:1.

O desbaste foi efetuado aos 15 dias após a emergência das plantas, de forma a manter uma planta por saco plástico. E após 40 dias foram transplantadas para área experimental com adubação orgânica (esterco), com três plantas por cova e no início do florescimento das plantas foi mantida apenas uma planta a que apresentava inflorescências hermafroditas.

A área plantada foi constituída por 18 fileiras com 24 plantas cada e consideradas como útil as 16 fileiras centrais, com 22 plantas por fileira, no espaçamento de 3 m x 2 m, com o total de 352 plantas e área útil de 2.112 m<sup>2</sup>, não avaliando a primeira e a última planta de cada fileira.

## **2.2. Características morfoagronômicas avaliadas**

Foram avaliados 17 caracteres agronômicos, três relacionados às características vegetativas da planta, sete relacionados as reprodutivas e sete as de qualidade dos frutos, descritas a seguir:

### **2.2.1. Características vegetativas**

a. Altura da planta (AP6); (AP12); (AP18): distância entre a superfície do solo até o ponto de inserção da folha mais nova, localizado no ápice caulinar, avaliada aos seis, 12 e 18 meses de idade, expressa em centímetros (cm);

b. Altura de inserção dos primeiros frutos (AIPF): altura de inserção da primeira flor funcional (que irá produzir frutos), no início da produção, de oito a 10 meses após o plantio, a partir da superfície do solo, contígua ao colo da planta, até o ponto de inserção do primeiro fruto, expressa em centímetros (cm);

c. Diâmetro do caule (DC6); (DC12); (DC18): medido a 20 cm acima do nível do solo, avaliado aos seis, 12 e 18 meses de idade;

### **2.2.2. Caracteres reprodutivos**

a. Precocidade (PREC): avaliada mediante indicação da data da primeira colheita de frutos;

b. Número de frutos comerciais por planta (NFC9); (NFC14): contagem de frutos comerciais presentes em cada planta aos nove e 14 meses após o plantio;

c. Número de frutos comerciais totais (NFCT): soma de frutos comerciais presentes em cada planta aos nove e 14 meses após o plantio;

d. Número de frutos deformados por planta (NFD9); (NFD14): contagem de frutos carpelóides, pentândricos e bananiformes presentes em cada planta, aos nove e 14 meses após o plantio;

e. Número de nós sem frutos (NNSF9); (NNSF14): avaliado aos nove e 14 meses após o plantio, na região denominada usualmente por “pescoço”, mediante contagem do número de nós que não produziram frutos;

f. Produtividade (PROD): Estimada pela multiplicação do número de frutos comerciais por planta (NFC) pelo peso médio do fruto por planta, considerando-se o espaçamento do plantio;

### **2. 2. 3. Caracteres de qualidade do fruto**

a. Comprimento de fruto (CF): expresso em cm, com o auxílio de um paquímetro de madeira mediu-se o comprimento da base ao ápice do fruto;

b. Diâmetro de fruto (DF): expresso em centímetros cm, com o auxílio de um paquímetro de madeira realizou-se a medição na parte de maior diâmetro do fruto;

- c. Massa de fruto (PF): expresso em gramas, pesou-se os frutos colhidos por planta em uma balança analítica. Os frutos foram colhidos no estágio 2 de maturação, ou seja,  $\frac{1}{4}$  maduro, com até 25% da casca amarela;
- d. Teor de sólidos solúveis (SS): expresso em o Brix ( $^{\circ}\text{Bx}$ ), obtido com auxílio de refratômetro digital portátil modelo r2mini Reicher;
- e. Firmeza do fruto (FF): expresso em  $\text{kg cm}^{-2}$ , determinada em frutos maduros íntegros na região central com auxílio de um eletrômetro, a partir de 03 (três) leituras;
- f. Diâmetro da cavidade interna do fruto (DCI): expresso em cm, mediu-se o diâmetro da cavidade na parte central do fruto. No caso de cavidades em formato de estrela, as medidas foram tomadas de uma extremidade a outra de maior de distância;
- g. Espessura da polpa (EP): expresso em cm, com o auxílio de um paquímetro tomou-se a medição da espessura da polpa de maior tamanho após o corte transversal do fruto.

### **2.3. Análise estatística**

Foram estimados a estatística descritiva , análise da correlação de Pearson e regressão linear para predição de produtividade. Estes procedimentos foram executados por meio do software R (R Development Core Team, 2018).

#### **2.4.1. Estatística descritiva: médias, desvios-padrão e coeficiente de variação**

Para determinar as médias, os desvios-padrão e os coeficientes de variação das características morfoagronômicas e de rendimento, consideraram-se as observações mensuradas nos 17 caracteres vegetativos e reprodutivo do mamoeiro.

#### **2.4.2. Análise de correlação**

Para estimar a relação de dependência entre os caracteres morfoagronômicos, da linhagem CNPMF-L78, utilizou-se a correlação de Pearson (PIMENTEL-GOMES, 2000). Foram avaliadas as estimativas de associações entre os caracteres morfoagronômicas, a fim de verificar quais variáveis apresentam maior poder de explicação da produtividade do mamoeiro.

Por meio da correlação de Pearson ( $r$ ), avaliaram-se as associações entre as variáveis morfoagronômicas analisadas.

$$r = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(X_i - \bar{X})}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2 (X_i - \bar{X})^2}}$$

Em que:  $Y_i$  e  $X_i$  são as  $i$ -ésimas observações das variáveis Y e X, enquanto  $\bar{Y}$  e  $\bar{X}$  são as médias das variáveis Y e X, respectivamente. O teste t foi usado para avaliar a significância da correlação entre as variáveis.

### 3. RESULTADOS E DISCUSSÃO

#### 3.1. Avaliação fenotípica entre os caracteres vegetativas do mamoeiro (Linhagem CNPMF-L78)

As médias, assim como os Coeficientes de Variação (CV%) para as características vegetativas do mamoeiro linhagem CNPMF-L78 são mostrados na (Tabela 1).

**Tabela 1.** Medidas descritivas referentes às características vegetativas do mamoeiro *Carica papaya* L. linhagem CNPMF-L78.

Variáveis	Mínima	Média	Mediana	Máxima	Desvio Padrão	CV%
AP6	0,75	1,22	1,20	1,90	0,19	15,74
AP12	1,25	1,99	2,00	3,10	0,24	12,24
AP18	1,65	2,29	2,30	3,50	0,23	10,12
AIPF	0,60	1,04	1,05	1,45	0,16	15,09
DC6	2,40	5,62	5,40	10,50	1,63	28,98
DC12	6,20	11,33	11,40	17,00	1,63	14,35
DC18	7,30	11,98	12,00	17,20	1,44	12,01

AP: Altura da planta avaliada aos seis, 12 e 18 meses de idade (cm); AIPF: Altura de inserção dos primeiros frutos (cm); DC: Diâmetro do caule avaliado aos seis, 12 e 18 meses de idade (cm).

O caractere AP, avaliada aos seis, 12 e 18 meses apresentou médias de 122, 199 e 229 cm respectivamente, valores de médias superiores, foram obtidos para essa mesma linhagem nos estudos de Carvalho (2015), a autora ponderou médias para o caractere AP em linhagem CNPMF-L78, com avaliação aos 6, 12 e 18 meses de idade, respectivamente 174,44; 267,32 e 306 cm. Os resultados aqui obtidos para a característica altura da planta, é favorável a produtividade em mamoeiro do Grupo Solo.

Plantas muito altas acima de 3,5m são desfavoráveis para a produtividade, por exibirem, entrenós mais compridos, frutos mais espaçados e menor longevidade de

colheita. Dessa forma o alto porte em mamoeiro representa uma característica negativa tanto para a produtividade, como para atividades em prática de colheita, por ser um empecilho na padronização em técnicas de colheita (MARTINS, 2013).

Nos estudos realizados por Silva (2006) foi constatado que plantas hermafroditas estéreis e plantas masculinas são quase sempre mais altas do que as plantas que tem menor expressão da esterilidade feminina. Portanto, é desejável que a plantas do grupo Solo cresça apresentando uma estatura média abaixo de 3m, no período de maior produtividade (18 a 24 meses), com entrenós curtos, promovendo menor espaço entre os frutos, o que favorecerá a colheita.

A altura de inserção do primeiro fruto (AIPF) apresentou valor médio de 104 cm, aos oito meses de idade. É preferível a seleção de variedades que iniciem a inserção do primeiro fruto a uma menor altura, entre 70 e 80cm (ALONSO et al., 2008). Oliveira et al. (2010) e Dias et al. (2011) corroboraram que a média ideal para o AIPF esteja abaixo de 80 cm, para proporcionar a precocidade e que está altamente relacionada a AIPF. Nessa perspectiva é aconselhável buscar plantas de mamoeiro que tendem ocorrer a inserção da primeira flor com baixa estatura para viabilizar a precocidade. Os pesquisadores citados, ainda, estabeleceram para a seleção de cultivares do grupo Solo, plantas com altura das primeiras flores inferior a 70 cm.

Para o diâmetro do caule (DC), obtiveram-se médias com 5,62; 11,33 e 11,98 cm, respectivamente para seis, 12 e 18 meses. As duas últimas médias avaliadas aos 12 e 18 meses respectivamente, foram consideradas altas para essa característica, indicando tendência da planta ao vigor, assegurando a capacidade de sustentar mais frutos de qualidade. Fraife Filho et al. (2001) e Silva et al. (2006), acrescentaram que, o conhecimento dessa variável é intimamente ligado a planta com maior potencial produtivo.

Os coeficientes de variação para altura da planta avaliados aos seis, 12 e 18 meses oscilaram em 15,74, 12,24 e 10,12%, respectivamente. Com os maiores valores associados à fase mais jovem da planta, como era de se esperar, pois o mamoeiro do grupo Solo tende a uniformidade da lavoura a partir dos três ou quatro meses, após a abertura da flor (BRAGA, 2020).

De acordo com os critérios de classificação de CV, para os caracteres vegetativos das variedades do mamoeiro, COSTA et al. (2002) consideraram que, para melhor compreensão acerca dos valores do CV, que se classificariam em quatro níveis (baixo, médio, alto e muito alto). Segundo Costa et al. (2002) e Pimentel Gomes (2009),

o CV de valores médio em relação AP ocorre com maior frequência em variedades de mamoeiro, com variação de aproximadamente 42,42%, evidenciando bons resultados neste estudo.

O coeficiente de variação para a variável altura de inserção do primeiro fruto correspondeu a uma variação de 15,09%, mostrando haver homogeneidade na dispersão dos dados. Os valores de AIPF estão dentro da caracterização de Costa et al. (2002), em que os valores de CV de 8,98 a 19,52% são considerados médios. Este padrão de CV ocorre com muita incidência em mamoeiro em condições gerais (PIMENTEL GOMES, 2009; COSTA et al., 2002), apresentando frequência analisada de 64,47% a 65,30%.

O diâmetro do caule para os meses seis, 12 e 18 indicaram alta variabilidade com os valores para o coeficiente de variação de 28,98; 14,35 e 12,01%, respectivamente, contudo, com tendência de redução com o crescimento vegetativo. Estes dados encontrados nesta pesquisa são corroborados pelos estudos realizados por Dantas et al. (2015) e Ramos et al. (2014) que identificaram valores de CV para o DC do mamoeiro com valores entre 10 a 20%, e contrasta com os estudos de Nascimento (2014) que obteve um CV de 5,21% para o diâmetro do caule. Justificando a necessidade de utilizar uma faixa de avaliação específica para cada caractere em suas diferentes condições edafoclimáticas (FERREIRA et al., 2016).

### **3.2. Variações fenotípicas entre características reprodutivas e de rendimento**

Na Tabela 2 obtêm-se as médias e as variações das características agrônômicas referentes à produção do mamoeiro. A produtividade, expressa pela massa média do fruto, apresentou CV com ampla variabilidade na ordem de 40,99% e média de 56,28 kg<sup>-1</sup>. Em seu primeiro ano o mamoeiro pode obter produtividade de até 60 frutos por planta, portando a média de frutos aqui obtida é considerado de alta produtividade (YAMANISHI et al., 2006).

**Tabela 2.** Medidas descritivas referentes às características produtivas do mamoeiro *Carica papaya* L. linhagem CNPMF-L78.

Variáveis	Mínimo	Média	Mediana	Máximo	Desvio Padrão	CV%
<b>PROD</b>	24,35	56,28	49,72	160,31	23,07	40,99
<b>PREC</b>	188,00	245,98	239,50	299,00	28,00	11,38
<b>NFC9</b>	10,00	27,29	21,00	91,00	15,60	57,18
<b>NFD9</b>	0,00	0,68	0,00	10,00	1,31	194,18
<b>NNSF9</b>	0,00	0,38	0,00	10,00	1,32	345,33
<b>NFC14</b>	10,00	28,18	26,50	82,00	11,01	39,07
<b>NFD14</b>	0,00	2,02	2,00	15,00	2,08	102,59
<b>NNSF14</b>	0,00	6,53	6,00	22,00	3,68	56,44
<b>NFCT</b>	24,00	55,47	49,00	158,00	22,74	40,99

PROD: Produtividade (Estimada); PREC: Precocidade; NFC: Número de frutos comerciais por planta (contagem no 9 e 14 meses, após plantio); NFCT: Número de frutos comerciais totais (Soma); NFD: Número de frutos deformados por planta (contagem no 9 e 14 meses após o plantio); NNSF: Número de nós sem frutos (contagem no 9 e 14 meses, após o plantio).

Portanto, os dados encontrados para a linhagem CNPMF-L78 são corroborados pelos estudos de DANTAS et al. (2015) onde as linhagens CPMF-L10 e L72 e todos os híbridos do grupo Solo apresentaram médias superiores a 40 t ha<sup>-1</sup>, demonstrando serem promissoras e passíveis de indicação futura no uso direto para o sistema de produção de mamão (LUCENA, 2013).

O início de colheita se deu aos 245 dias após o plantio. A precocidade em variedades de Sunrise Solo e Tainung nº 1 tiveram início de colheita aos 250 e 257 dias após o plantio (LUCENA, 2013). Plantas de baixo porte tendem a ter maior precocidade, comportamento positivo para esse caractere foi avaliado neste estudo.

A contagem dos números de frutos comerciais (NFC9); (NFC14), obtiveram proximidades em suas médias 27,29 e 28,18, estes valores refletem a produção de frutos na média de uma planta em uma única colheita. Obtendo na soma dos números de frutos comerciais totais um rendimento médio de 55,47 frutos, que é considerado alto na produção de acordo com Luz et al. (2015).

Os valores médios foram expressos para as características NFD9; NNSF9; NFD14 e NNSF14, 0,68; 0,38; 2,02 e 6,53 respectivamente (Tabela 2), mostrando haver ampla variabilidade para estes caracteres que são de fundamental importância para os programas de melhoramento, pois estão diretamente relacionadas à produtividade. Segundo LUCENA (2013) quanto maiores os valores de NFD e NNSF, conseqüentemente menor vai ser a produtividade. Os valores para esses caracteres



foram relativamente baixo neste estudo, indicando que a linhagem CNPMF-L78 é passível a produtividade sob determinadas condições.

Os valores do CV para as características avaliadas oscilaram de médio a muito alto. A precocidade obteve o menor CV entre as características reprodutivas, com 11,38%. A precocidade é uma característica hereditária (SIMÃO, 1998) e plantas com esta característica tendem a iniciar a floração entre 3 a 4 meses após o plantio, com início de produção de frutos dos 8 a 10 meses de plantio (DANTAS et al., 2015).

A característica número de frutos comerciais por planta foi a que se apresentou valores de CV considerados alto, 57,18 e 39,07% (Tabela 2). Foi observado um CV para número de frutos comerciais totais de 40,99%. Essa alta variação é vista como boa, pois qualifica os frutos considerados para o mercado, quanto ao tamanho, massa e diâmetro do fruto (BARROS et al., 2017).

Foi verificado alto índice de variação de CV para o número de frutos deformados por planta, ou seja, frutos carpelóides, pentândricos e bananiformes, um menor valor é desejável para essa característica cujo menor valor foi observado aos 14 meses de avaliação 39,07% (VETORRAZI, 2020). O caráter número de nós sem frutos, também mostrou CV menor, quando quantificado aos 14 meses, 56,44% (Tabela 2). Coeficientes de variação (CV) altos são descritos por SILVA et al. (2008), principalmente para características que envolvem contagem de frutos comerciais, carpeloides e pentândricos, resultado da forte influência do ambiente.

### **3.3. Variação fenotípica entre as características de qualidade do fruto e de rendimento**

Mensurou-se o comportamento fenotípico para as características CF, DF e PF que, exibiram médias de 15,64 cm; 8,75 cm e 609,00 g, respectivamente (Tabela 3). Esses dados coadunam com os estudos de REIS et al. (2015), em que se verificaram médias semelhantes à deste estudo para linhagem grupo Solo L26, com 15,41cm; 8,71cm; 550,40g, na ordem. Os genótipos pertencentes ao grupo Solo, apresentam frutos pequenos e de polpa avermelhada, e são os preferidos para exportação (REIS et al., 2015).

**Tabela 3.** Medidas descritivas referentes as características de qualidades do fruto do mamoeiro *Carica papaya* L. linhagem CNPMF-L78.

Variáveis	Mínimo	Média	Mediana	Máximo	Desvio Padrão	Coefficiente de variação
CF	11,95	15,64	15,77	18,50	0,95	6,05
DF	6,90	8,75	8,78	10,43	0,57	6,54
PF	322,75	609,00	613,67	860,50	102,30	16,80
FF	1,50	2,49	2,45	4,27	0,50	19,94
DCI	3,20	4,54	4,55	5,78	0,41	9,12
EP	1,73	2,39	2,34	3,47	0,28	11,67
TSS	10,10	12,34	12,29	15,23	0,70	5,66

CF: Comprimento de fruto (cm); DF: Diâmetro de fruto (cm); PF: Massa de fruto (cm); FF: Firmeza do fruto (kg cm<sup>-2</sup>); DCI: Diâmetro da cavidade interna do fruto (cm); EP: Espessura da polpa (cm); TSS: Teor de sólidos solúveis (°Brix).

A massa do fruto está dentro da média estabelecida para o grupo Solo, entre 350 a 600 g (DIAS et al., 2011; NASCIMENTO et al., 2018). E está em conformidade como padrão de frutos que atende ao mercado nacional e internacional (FERREIRA et al., 2020). O teor de sólidos solúveis 12,34 °Brix está dentro do estabelecido na Instrução Normativa 4/2010 de Padrão de Identidade e Qualidade (PIQ) do Ministério da Agricultura e Pecuária (MAPA, 2010), que estabelece valores mínimos de 11 °Brix (FERREIRA et al., 2020). Valores semelhantes com variação de 9,9 a 12,5 °Brix, foram obtidos por Silva et al. (2017) e Nascimento et al. (2018).

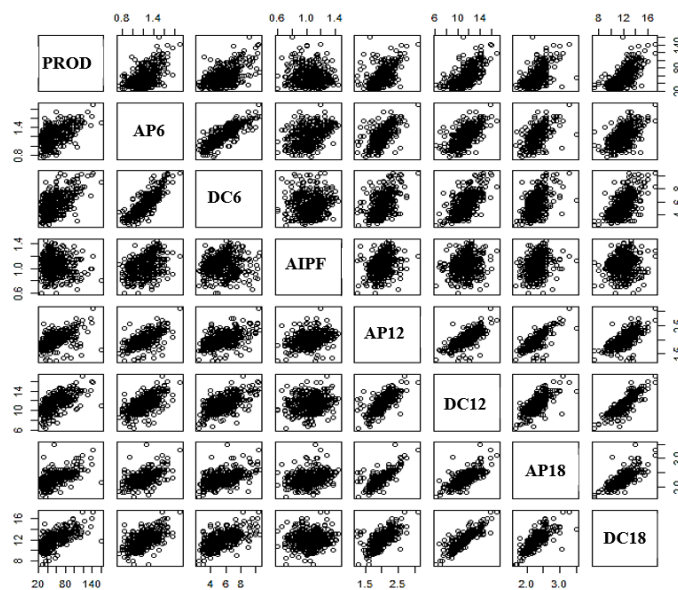
A firmeza do fruto, o diâmetro da cavidade interna e a espessura da polpa obtiveram médias 2,49 kg cm<sup>-2</sup>, 4,54 cm e 2,39 cm, respectivamente (Tabela 3). A firmeza do fruto tem grande importância, pois confere resistência ao fruto, proporcionando longevidade nas prateleiras. O diâmetro da cavidade interna e a espessura da polpa divergem com o relatado na literatura, em que o diâmetro da cavidade interna e a espessura da polpa estão diretamente associados, de forma que, quanto menor o diâmetro da cavidade interna, maior a espessura da polpa (DIAS et al., 2011). Assim, a maior espessura da polpa irá condicionar maior rendimento de polpa. Neste estudo, a EP está ideal, com valores acima de 2,0 cm. Todavia o DCI está duas vezes maior que EP, enquanto que o normal seria estar duas vezes menor. (YAMANISHI et al., 2006). Essa característica sofre influências das condições edafoclimáticas. Dantas (2000), diz que o excesso de chuvas e elevada umidade relativa afeta a qualidade dos frutos.

Os coeficientes de variação para as características destinadas a qualidade do fruto do mamoeiro oscilaram de 5,66% a 19,94% (Tabela 3). Os caracteres CF, DF, TSS

e DCI, obtiveram CV% abaixo de 10%, mostrando pouca influência do ambiente. Os caracteres PF, FF e EP exibiram CV de 10 a 20%. Em relação a frequência das variações encontradas para EP e FF, ocorre com maior frequência, respectivamente os valores de 42,76% e 80% e DF e TSS variação ocorre com baixa frequência de 18,91% e 18,51%, segundo caracterização estabelecida por Costa et al. (2002) e Pimentel Gomes (2009). A variação nas características físicas dos frutos está relacionada principalmente a influência ambiental, como solo, clima, época de plantio, além das condições de manuseio na colheita, tratos culturais e características da própria cultivar (FAGUNDES e YAMANISHI, 2001).

### 3.4. Correlação para as características vegetativas.

Estimativas positivas das correlações de Pearson foram mensuradas entre as características vegetativas AP e DC avaliados aos seis, 12 e 18 meses e a AIPF, avaliada a partir da inserção da primeira flor funcional (que produz frutos) e foram registradas na Figura 1 e Tabela 4.



**Figura 1.** Estimativa da correlação entre produtividade e as características vegetativas. AP: Altura da planta; AIPF: Altura de inserção dos primeiros frutos; DC: Diâmetro do caule.

**Tabela 4.** Estimativa das correlações de Pearson entre variáveis produtividade e as características vegetativas.

Caracteres	PROD	AP6	DC6	AIPF	AP12	DC12	AP18	DC18
<b>PROD</b>	1,00	0,56**	0,57**	-0,08 <sup>ns</sup>	0,53**	0,65**	0,57**	0,66**
<b>AP6</b>	0,56**	1,00	0,84**	0,34**	0,64**	0,64**	0,61**	0,60**
<b>DC6</b>	0,57**	0,84**	1,00	0,05 <sup>ns</sup>	0,52**	0,63**	0,51**	0,61**
<b>AIPF</b>	-0,08 <sup>ns</sup>	0,34**	0,05 <sup>ns</sup>	1,00	0,28**	0,15**	0,26**	0,10 <sup>ns</sup>
<b>AP12</b>	0,53**	0,64**	0,52**	0,28**	1,00	0,74**	0,79**	0,68**
<b>DC12</b>	0,65**	0,64**	0,63**	0,15**	0,74**	1,00	0,74**	0,87**
<b>AP18</b>	0,57**	0,61**	0,51**	0,26**	0,79**	0,74**	1,00	0,76**
<b>DC18</b>	0,66**	0,60**	0,61**	0,10*	0,68**	0,87**	0,76**	1,00

AP: Altura da planta; DC: Diâmetro do caule (avaliados aos 6, 12 e 18 meses de idade); AIPF: Altura de inserção dos primeiros frutos (primeira flor funcional). <sup>ns</sup> -Não significativo ( $p > 0.05$ ); \* - significativo ( $0.01 < p \leq 0.05$ ); \*\* - significativo ( $p \leq 0.01$ ) pelo teste t.

A relação para altura da planta foi positiva em relação ao diâmetro do caule, com valores do coeficiente de correlação ( $r$ ) superior a 0,51. Os maiores valores estimados para o  $r$  foram entre as variáveis AP6 e DC6 (0,84) e AP18 e DC18 (0,76). Essa associação indica tendência à capacidade de sustentar vários frutos (FERREIRA et al., 2012; DANTAS et al., 2015; SILVA et al., 2017). Com base nestes autores a relação linear entre AP e DC contribuem para distinção dos indivíduos por resultar em plantas mais produtivas, por suportar maior quantidade de frutos além de apresentar menor tendência ao acamamento (flexão do caule).

Associações positivas moderadas foram observadas entre AP e AIPF, em que o maior e o menor valores foram referentes as variáveis AP6 (0,34) e AP18 (0,26), nesta ordem. Valores de média magnitude entre esses caracteres podem ser devidos ao alto porte da planta, plantas altas, implicará em maior altura dos primeiros frutos e essa característica está diretamente associada aos entre nós mais longos e maior espaçamento entre os frutos, o que não é desejável para se obter boa produtividade.

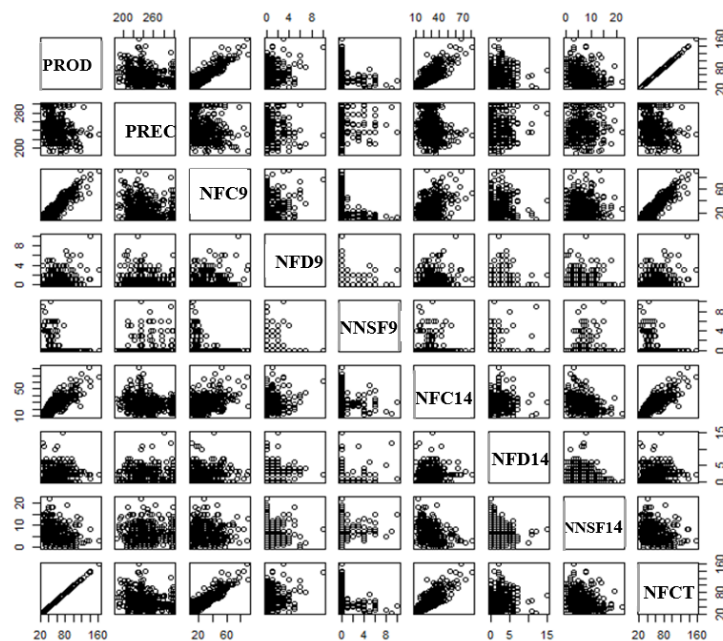
Correlação positiva, porém, de baixa magnitude foi expressa na relação AIPF e DC, em que o menor e o maior valores de  $r$  foram ligadas as variáveis DC6 (0,05) e DC12 (0,14), respectivamente. Estes resultados corroboram aos obtidos por Ide (2008), ao constatar correlações fenotípicas positivas entre AP x DC x APF, o que sugere comportamento similar para o estágio vegetativo.

Em relação a associação dos caracteres vegetativos com a produtividade estes correlacionaram-se positivamente, com exceção da variável AIPF que, apresentou

coeficiente negativo  $r$  (-0,08). O que já era esperado, visto que a frutificação precoce é caracterizada pela menor altura da inserção da primeira flor funcional, divergindo com valores encontrados neste estudo. A característica AIPF é de extrema importância, visto que é através dela que se dará o início da produção, assim como o aumento ou a diminuição da longevidade da colheita (COSTA e PACOVA, 2003; NASCIMENTO, 2014).

### 3.4.1. Correlação para as características produtivas e de rendimento

As correlações encontradas para os caracteres de produção do fruto: Precocidade; Número de frutos comerciais por planta; Número de frutos comerciais totais; Número de frutos deformados por planta; Número de nós sem frutos são mostrados da Figura 2.



**Figura 2.** Estimativa da correlação entre as características produtivas. PROD: Produtividade; PREC: Precocidade; NFC: Número de frutos comerciais por planta; NFCT: Número de frutos comerciais totais; NFD: Número de frutos deformados por planta; NNSF: Número de nós sem frutos.

Associações negativas foram exibidas pela variável PREC em relação aos caracteres de produção e rendimentos do fruto (Tabela 5), exceto para as variáveis de NNSF9 e NNSF14 que apresentaram fraca associação com a precocidade (0,07) e (0,03), nessa ordem. A PREC é uma qualidade de grande interesse para estimar o rendimento, pois avalia precocemente a planta, quanto ao início da produção dos frutos, resultados que são atribuídos ao alto porte da planta (DIAS et al., 2011).

**Tabela 5.** Estimativa das correlações de Pearson entre variáveis reprodutivas e de rendimento.

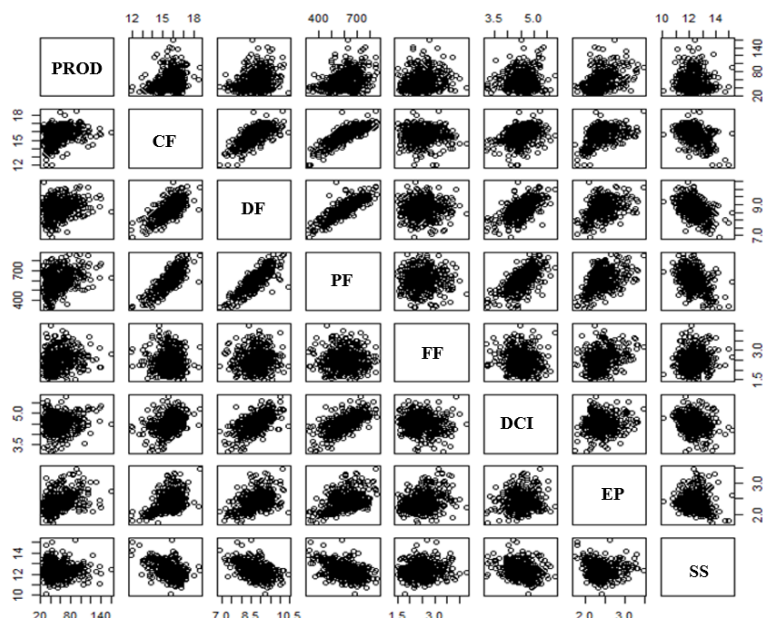
Caracteres	PROD	PREC	NFC9	NFD9	NNSF9	NFC14	NFD14	NNSF14	NFCT
<b>PROD</b>	1,00	-0,32**	0,90**	0,30**	-0,16**	0,79**	0,10*	-0,22**	1,00
<b>PREC</b>	-0,32**	1,00	-0,30**	-0,16**	0,07 <sup>ns</sup>	-0,23**	-0,07 <sup>ns</sup>	0,03 <sup>ns</sup>	-0,32**
<b>NFC9</b>	0,90**	-0,30**	1,00	0,27**	-0,22**	0,44**	0,10*	-0,05 <sup>ns</sup>	0,90**
<b>NFD9</b>	0,30**	-0,16**	0,27**	1,00	0,05 <sup>ns</sup>	0,24**	0,07 <sup>ns</sup>	-0,05 <sup>ns</sup>	0,30**
<b>NNSF9</b>	-0,16**	0,07 <sup>ns</sup>	-0,22**	0,05 <sup>ns</sup>	1,00	-0,02 <sup>ns</sup>	0,01 <sup>ns</sup>	0,13*	-0,16**
<b>NFC14</b>	0,79**	-0,23	0,44**	0,24**	-0,02 <sup>ns</sup>	1,00	0,07 <sup>ns</sup>	-0,39**	0,79**
<b>NFD14</b>	0,10*	-0,07 <sup>ns</sup>	0,10*	0,07 <sup>ns</sup>	0,01 <sup>ns</sup>	0,07 <sup>ns</sup>	1,00	-0,28**	0,10*
<b>NNSF14</b>	-0,22**	0,03 <sup>ns</sup>	-0,05 <sup>ns</sup>	-0,05 <sup>ns</sup>	0,13*	-0,39**	-0,28**	1,00	-0,22**
<b>NFCT</b>	1,00	-0,32**	0,90**	0,30**	-0,16**	0,79**	0,10*	-0,22**	1,00

PROD: Produtividade; PREC: Precocidade; NFC: Número de frutos comerciais por planta; NFCT: Número de frutos comerciais totais; NFD: Número de frutos deformados por planta; NNSF: Número de nós sem frutos. <sup>ns</sup> -Não significativo ( $p > 0.05$ ); \* - significativo ( $0.01 < p \leq 0.05$ ); \*\* - significativo ( $p \leq 0.01$ ) pelo teste t.

Correlação de altos valores ocorreram entre as variáveis NFC, NFCT e NFD, como mostradas na Tabela 5. Tais características são de alta magnitude para produção em mamoeiro, visto que qualificam os frutos que serão comercializados. Já a correlação entre NFC x NNSF comportou-se de forma negativa, todavia essa expressão é um bom indicativo para a obtenção de maior número de frutos. A qual foi evidenciada com a correlação positiva entre o NFC e PROD, conferindo alto potencial para compor modelos de estimativa da produtividade. Resultados semelhantes foram obtidos por LUCENA (2013), ao estudar linhagens do grupo solo e híbridos de mamoeiro.

### 3.4.2. Correlação para as características de qualidade do fruto e rendimento

A Figura 3 exhibe correlações positivas e negativas para as características de qualidade e rendimento do fruto comprimento de fruto; (DF) diâmetro de fruto; (PF) peso de fruto; (FF) firmeza do fruto; (DCI) diâmetro da cavidade interna do fruto; (EP) espessura da polpa; (SS) sólidos solúveis.



**Figura 3.** Estimativa da correlação entre as características de qualidade e rendimento do fruto. CF: Comprimento de fruto; DF: Diâmetro de fruto; PF: Peso de fruto; FF: Firmeza do fruto; DCI: Diâmetro da cavidade interna do fruto; EP: Espessura da polpa; SS: Sólidos solúveis.

As características CF, DF, PF e EP foram as que obtiveram maiores correlações com a produtividade mostrados na ordem (0,23), (0,26), (0,30) e (0,41). A aparência dos frutos e, a combinação de seus atributos de qualidade interfere diretamente na aceitabilidade dos frutos pelos consumidores (REIS et al., 2015).

Todavia, a característica SS mostrou associação negativa com a PROD ao expor valor do coeficiente de correlação igual a -0,08 (Tabela 6). Esses dados corroboram com os autores Oliveira et al. (2010) e Quintal (2012), onde o SS foi a única característica a se correlacionar negativamente com produtividade, enquanto que as demais características apresentaram correlações positivas moderadas para qualidades do fruto.

**Tabela 6.** Estimativa das correlações de Pearson entre as características de qualidade do fruto e rendimento

Caracteres	PROD	CF	DF	PF	FF	DCI	EP	SS
<b>PROD</b>	1,00	0,23**	0,26**	0,30**	0,17**	0,13**	0,41**	-0,08 <sup>ns</sup>
<b>CF</b>	0,23**	1,00	0,69**	0,83**	-0,02 <sup>ns</sup>	0,37**	0,39**	-0,44**
<b>DF</b>	0,26**	0,69**	1,00	0,85**	0,02 <sup>ns</sup>	0,63**	0,42**	-0,46**
<b>PF</b>	0,30**	0,83**	0,85**	1,00	0,01 <sup>ns</sup>	0,67**	0,42**	-0,44**
<b>FF</b>	0,17**	-0,02 <sup>ns</sup>	0,02 <sup>ns</sup>	0,01 <sup>ns</sup>	1,00	-0,09 <sup>ns</sup>	0,31**	0,09 <sup>ns</sup>
<b>DCI</b>	0,13**	0,37**	0,63**	0,67**	-0,09 <sup>ns</sup>	1,00	0,11**	-0,24**
<b>EP</b>	0,41**	0,39**	0,42**	0,42**	0,31**	0,11**	1,00	-0,08 <sup>ns</sup>
<b>SS</b>	-0,08 <sup>ns</sup>	-0,44**	-0,46**	-0,44**	0,09 <sup>ns</sup>	-0,24**	-0,08 <sup>ns</sup>	1,00

CF: Comprimento de fruto; DF: Diâmetro de fruto; PF: Peso de fruto; FF: Firmeza do fruto; DCI: Diâmetro da cavidade interna do fruto; EP: Espessura da polpa; SS: Sólidos solúveis. <sup>ns</sup> - Não significativo ( $p > 0.05$ ); \* - significativo t ( $0.01 < p \leq 0.05$ ); \*\* - significativo ( $p \leq 0.01$ ) pelo teste t.

O teor de sólidos solúveis é uma característica de difícil precisão, pois pode haver ampla variação devida a fatores como adubação, por exemplo. Sendo assim, é um caráter importante a ser considerado para a comercialização, haja vista a apreciação do fruto de forma *in natura*, pelo seu sabor adocicado. Outra característica de grande importância para o produtor no que diz respeito a produtividade é a FF, a qual atribui qualidade e vida útil pós-colheita, além de oferecer resistência durante o transporte, armazenamento e manuseio, de forma a proporcionar que o fruto chegue com boa qualidade nas prateleiras (MORAIS et al., 2007). No entanto, o valor da correlação para este caractere foi de (0,17), indicando baixa correlação com a produtividade. A melhor correlação da FF foi quando associada a EP, exibindo coeficiente de correlação (0,31) essa variável é de suma importância para mensurar o rendimento, de grande interesse econômico.

O DCI mostrou associações com os caracteres de qualidade do fruto, exceto para FF e SS, os quais exibiram coeficientes de correlação negativos, expresso pelos valores (-0,09), (-0,24), nesta ordem. Contudo, obteve-se alta correlação com DF (0,63) e PF (0,67). A associação entre DCI, DF e PF é um dos fatores de qualidade dos frutos de mamão assim como, também, para seleção de genótipos superiores (DIAS et al., 2011).

O conhecimento da correlação entre as características é de extrema importância na predição de produtividade, pois mensura a associação entre características e oportuniza avaliar a interação de um caráter sobre outro (SILVA et al., 2016). Nesta vertente a identificação de variáveis de alta correlação, pode favorecer a seleção de plantas com características desejáveis pela predição de produtividade. A compreensão das variáveis morfoagronômicas da cultura do mamoeiro tem sua importância alicerçada na economia do mercado de frutos no país.

#### **4. CONCLUSÃO**

Com base na análise de correlação, foi possível identificar estimativas de alta significância entre altura da planta, diâmetro do caule, número de frutos comerciais, número de frutos comerciais totais com a produtividade. A característica altura da planta



foi determinante nas variações ocorridas sobre a característica altura e inserção dos primeiros frutos e precocidade sobre a produção por planta.

As características morfoagronômicas que demonstraram elevado grau de relacionamento pode fornecer subsídio para a prática da seleção das melhores linhagens além de sustentar a escolha de uma característica em detrimento de outra, tanto para alcance de progresso genético em programas de melhoramento, quanto para estimativa a produtividade.

## REFERÊNCIA

- ALONSO, M.; TORNET, Y.; RAMOS, R.; FARRÉS, E.; CASTRO, J.; RODRÍGUEZ, M. C. Evaluación de tres cultivares de papaya del Grupo Solo basada em caracteres de crecimiento y productividad. **Cultivos Tropicales, La Habana**, v. 29, n. 2, p. 59-64, 2008.
- BARROS, G. B. A.; AREDES, F. A. S.; RAMOS, H. C. C.; SANTA-CATARINA, R.; PEREIRA, M.G. Combining ability of recombinant lines of papaya from backcrossing for sexual conversion. **Revista Ciência Agronômica** v.48p.166-174, 2017
- BRAGA, H. F. Mamão: Aspectos Econômicos, Biológicos e Potencialidades no Processamento Para obtenção do Néctar. **Enciclopédia Biosfera**, Centro Científico Conhecer - Jandaia-GO, v.17 n.31, p.140, 2020.
- BRITO, T. S.; PAN, R.; VITTO, D. C.; RUPPENTHAL, V.; MACEDO JR, E. K. Análise de correlação e regressão da produção de feijão em diferentes regiões paranaenses. **Revista Cultivando Saber**, v.12, n.1, p.43- 53, 2019.
- CARVALHO, A. M. de; MENDES, A. N G.; CARVALHO, G. R.; BOTELHO, C. E. GONÇALVES, F. M. A.; FERREIRA, A. D. Correlação entre crescimento e produtividade de cultivares de café em diferentes regiões de Minas Gerais, Brasil. **Pesq. Agropecuária. bras.** Brasília, v.45, n.3, p.269-275, 2010.
- CASTRO, D. G.; FERNANDES, M. C. N.; FÉLIX, M. R.; CAZASSA, R. S.; TOMÉ, L. M.; BOTELHO, F. B. S. Estimativas de associação entre caracteres agronômicos na seleção de genótipos de arroz de terras altas. **Magistra**, Cruz das Almas – BA, v.30, p.359-367, 2019.
- COSTA, A. F. S.; PAVOCA, B. E. V. Caracterização de cultivares, estratégias e perspectivas de melhoramento genético do mameiro. In: **MARTINS, D. S.; COSTA, A. F. S. (Ed.)**. A cultura do mamoeiro: tecnologias de produção. Vitória, ES: Incaper , p. 58-102, 2003.
- COSTA, A. N.; COSTA, A. de F. S. da, Nutrição e adubação. In: **Martins, D. dos S.; Costa, A. de F. S. da. A cultura do mamoeiro: tecnologias de produção**. Incaper, Vitória, ES. 497p., 2003.
- COSTA, N. H. A. D.; SERAPHIN, J. C.; ZIMMERMANN, F.J.P. Novo método de classificação de coeficientes de variação para a cultura do arroz de terras altas. **Pesquisa Agropecuária Brasileira**, v.37, p.243-249, 2002.
- DALCHIAVON, F. C. **Correlações de Pearson e geoestatísticas entre a produtividade de Cana-de-Açúcar, estabelecida em dois métodos de colheita, e atributos físico-químicos do solo** (tese de doutorado). Faculdade de Engenharia – UNESP - Campus de Ilha Solteira. Estado de São Paulo, p.109, 2012.
- DANTAS, J. L. L. Mamão produção. **IN: Mamão. Produção: aspectos técnicos / Aldo Vilar Trindade, organizador**; Embrapa Mandioca e Fruticultura (Cruz das Almas, BA). — Brasília: Embrapa Comunicação para Transferência de Tecnologia, 77p., 2000. (Frutas do Brasil; 3).

DANTAS, J. L. L.; LUCENA, R. S.; BOAS, S. A. V. Avaliação Agronômica de Linhagens e Híbridos de Mamoeiro. **Rev. Bras. Frutic.** Jaboticabal - SP, v. 37, n. 1, p. 138-148, 2015.

DIAS, L.P.D.; OLIVEIRA, E.J.; DANTAS, J.L.L. Avaliação de genótipos de mamoeiro com uso de descritores agronômicos e estimação de parâmetros genéticos. **Pesquisa Agropecuária Brasileira**, Brasília, v.46, n.11, p.1471-1479, 2011.

DIAS, N. L. P.; OLIVEIRA, E. J.; DANTAS, J. L. L. Avaliação de genótipos de mamoeiro com uso de descritores agronômicos e estimação de parâmetros genéticos. **Pesquisa Agropecuária Brasileira**, Brasília, v.46, n.11, p.1471-1479, 2015.

CARVALHO, E. de M. L. **Novos genótipos de mamoeiro com adaptação ao recôncavo e extremo sul baiano** (Dissertação, p.116). Pós-Graduação em Recursos Genéticos Vegetais da Universidade Federal do Recôncavo da Bahia e Embrapa Mandioca e Fruticultura, Cruz das almas, BA, 2015.

FAGUNDES, G. R.; YAMANISHI, O. K. Características físicas e químicas de frutos de mamoeiro do grupo 'Solo' comercializados em quatro estabelecimentos de Brasília- DF. **Revista Brasileira de Fruticultura**, v.23, p.345-350, 2001.

FERREIRA, J.P.; SCHMILDT, O.; SCHMILDT, E.R.; PIANTAVINHA, W.C.; CATTANEO, L.F. Correlações entre características morfo- agronômicas de acessos de mamoeiro. **Enciclopédia Biosfera - Centro Científico Conhecer**, Goiânia, v.8, n.14, p.247, 2012.

FERREIRA, J.P., SCHMILDT, E.R., SCHMILDT, O., CATTANEO, L.F., ALEXANDRE, R.S., CRUZ, C.D. Comparação de métodos de classificação do coeficiente de variação em mamão. **Revista Ceres**, v.63, p.138-144, 2016.

FERREIRA, J. P.; SCHMILDT, O.; SILVA, C. A. da; NASCIMENTO, A. L.; SCHMILDT, E. R.; ALEXANDRE, R. S.; CATTANEO, L. F.; FERREGUETTI, G. A.; OLIVEIRA V. de S. Dimensionamento amostral para frutos em cultivares comerciais de mamoeiro avaliados a campo. **Revista Ifes Ciência**. 6ISSN 2359-4799 v. 6, n. 4, p. 67-77, 2020.

FRAIFE FILHO, G. de A.; DANTAS, J. L. L.; LEITE, J. B. V.; OLIVEIRA, J. R. P. Avaliação de variedades de mamoeiro no extremo sul da Bahia. **Magistra**, v.13, p.37-41, 2001.

GARCIA, R. D. C.; COSTA, E. B. da; LOSS, W. R. Custos de Produção do Mamoeiro. In **MARTINS, D. dos S.; COSTA, A. de F. S. da. A cultura do mamoeiro: tecnologias de produção**: Incaper, p. 497, Vitória, ES 2003.

GUIMARÃES, B. V. C.; DONATO, S. L. R.; AZEVEDO, A. M.; ASPIAZÚ, I.; SILVA JUNIOR, A. A. e. Prediction of 'Gigante' cactus pear yield by morphological characters and artificial neural networks. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.22, n.5, p.315-319, 2018.

GUIMARÃES, B. V. C.; DONATO, S. L. R.; ASPIAZÚ, I.; AZEVEDO, A. M.; CARVALHO, A. J. Comparison of Methods for Harvest Prediction in 'Gigante' Cactus Pear. **Journal of Agricultural Science**, v.11, n.14, 2019.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Cidades e estados**. 2909802. Cruz das Almas- BA, 2020. Disponível em: <https://cidades.ibge.gov.br/brasil/ba/cruz-das-almas/coordenadas>. Acessado em: 22.07.2021.

IDE, C. D. **Melhoramento genético do mamoeiro (*Carica papaya* L.): Parâmetros genéticos e capacidade combinatória em ensaios de competição de cultivares** (Tese de Doutorado, 139p.). Universidade Estadual do Norte Fluminense, Campos dos Goytacazes, RJ, 2008.

IUSS Working Group WRB. World reference base for soil resources 2014, update 2015. **International soil classification system for naming soils and creating legends for soil maps**. Rome: FAO; 2015. (World Soil Resources Reports, 106).

LUCENA, R.S. **Caracterização agrônômica de novas linhagens e híbridos de mamoeiro (*Carica papaya* L.)**, (Dissertação 122 p). Universidade Federal do Recôncavo da Bahia, Cruz das Almas, UFRB, 2013.

LUZ, L. N. da; PEREIRA, M. G.; BARROS, F. R.; BARROS, G. de B. FERREGUETTI, G. A. Novos híbridos de mamoeiro avaliados nas condições de cultivo tradicional e no semiárido brasileiro. **Revista Brasileira de Fruticultura [online]**. v. 37, n. 1, 2015. [Acessado 8 Agosto 2021], pp. 159-171. Disponível em: <<https://doi.org/10.1590/0100-2945-069/14>>.

MACEDO, C. M. P. de. **Avaliação de híbridos elites de mamão (*Carica papaya* L.) e seus cruzamentos recíprocos, quanto a qualidade fisiológica de sementes e o potencial agrônômico** (Tese doutorado 110 p). Universidade estadual do norte fluminense- Darcy Ribeiro Campos dos Goytacazes – RJ, 2012.

MAPA. Ministério da Agricultura, Pecuária e Abastecimento. 2010. **Instrução Normativa 4/2010**: Regulamento técnico do mamão. 2010.

MARTINS, M. L. **Avaliação agrônômica de genótipos de mamoeiro em Mossoró, RN** (Monografia). Mossoró, UFERSA, 41p. 2013.

MORAIS, P. L. D.; SILVA, G. G.; MENEZES, J. B.; MAIA, F. E. N.; DANTAS D. J.; SALES JÚNIOR, R. Pós-Colheita De Mamão Híbrido Uenf/ Caliman 01 Cultivado No Rio Grande Do Norte. **Rev. Bras. Frutic.** Jaboticabal – SP, v.29, n.3, p.666-670, 2007.

MOURA, M. C. F. de. **Correlação entre produtividade em Cana- de- Açúcar e índices de vegetação espectrais: estudo de caso na região de oratórios, MG** (tese de doutorado p. 93). Viçosa- Minas Gerais, 2013.

NAKASONE, H. Y.; LAMOUREUX, C. Transitional forms of hermaphroditic papaya flowers leading to complete maleness. **Journal of the American Society for Horticultural Science**, Mount Vernon, v.107, p.589-592, 1982.

NASCIMENTO, A. L. **Melhoramento Genético do Mamoeiro: Novos Híbridos Para o Norte do Espírito Santo (dissertação)**. Universidade Federal do Espírito Santo, Centro Universitário Norte do Espírito Santo, Programa de Pós-Graduação em Agricultura Tropical. São Mateus- ES, p. 93, 2014.

NASCIMENTO, A.L.; NASCIMENTO, A. L.; SCHMILDT, O.; SANTOS, K. T. H.; MALIKOUSKI, R. G.; ALEXANDRE, R. S.; CATTANEO, L. F.; AMARAL, J. A. T.;

CZEPAK, M. P.; FERREGUETI, G. A.; SCHMILDT, E. R. Evaluation of new papaya hybrids. **African Journal of Agricultural**, v.13, n.25, p.1283-1290, 2018.

NOGUEIRA, A. P.; SEDIYAMA, Y.; SOUZA, L. B.; HAMAWAKI, O. T.; CRUZ, C. D.; FERREIRA, D. G. Análise de trilha e correlações entre caracteres em soja cultivada em duas épocas de semeadura. **Bioscience Journal**, v.28, n.6, p.877-888, 2012

OLIVEIRA, A. M. G.; COELHO, E. F. Calagem e adubação para mamoeiro. **In.: BORGES, A. L. e SOUZA, L. S.** Recomendações de calagem e adubação para abacaxi, acerola, banana, laranja, tangerina, lima ácida, mamão, mandioca, manga e maracujá. Embrapa Mandioca e Fruticultura, Cruz das Almas, p.108-125, 2009.

OLIVEIRA, E.J.; LIMA, D.S.; MACHADO, M.D.; LUCENA, R.S.; MOTTA, T.B.N.; DANTAS, J.L. Correlações genéticas e análise de trilha para número de frutos comerciais por planta em mamoeiro. **Pesquisa Agropecuária Brasileira, Brasília**, v.45, p.855-862, 2010.

OLIVEIRA, S. L. de; SOUZA, T. A. N. de; SOARES, D. P.; LEANDRO, R. I.; FILHO, A. G. **Correlação entre caracteres morfoagronômicos em cultivares de Girassol em cultivo irrigado no norte de minas gerais.** 9º FEPEG- Fórum de Ensino, Pesquisa, Extensão e Gestão.Campo Universitário Professor Darcy Ribeiro. A humanização na ciência, tecnologia e inovação, 2015.

PIMENTEL-GOMES F. Curso de estatística experimental. 15ª ed. Piracicaba, **FEALQ**. 2009, 451p.

QUINTAL, S. S. R.; VIANA, A. P.; GONÇALVES L. S. A.; PEREIRA M. G.; AMARAL JUNIOR A. T. Divergência genética entre acessos de mamoeiro por meio de variáveis morfoagronômicas. **Ciências Agrárias**, v.33, p.131-142, 2012.

R CORE TEAM. *R: uma linguagem e ambiente para computação estatística.* Viena: RFoundation for Statistical Computing, 2018.

RAMOS, H. C. C.; PEREIRA, M. G.; VIANA, A. P.; DA LUZ, L. N.; CARDOSO, D. L.; FERREGUETTI, G. A. Seleção Combinada na População Retrocruzada de Mamão (Carica mamão L.) pela Metodologia de Modelo Misto. **Americano Journal of Plant Sciences**, v.5, p. 2973-2983, 2014.

REIS, R. C.; VIANA, E. S.; JESUS, J. L.; DANTAS, J. L. L.; LUCENA, R. S. Caracterização físico-química de frutos de novos híbridos e linhagens de mamoeiro. **Pesquisa Agropecuária Brasileira**, v.50, n.3, p.210-217, 2015.

SANTOS H. G.; JACOMINE P. K. T.; ANJOS L. H. C.; OLIVEIRA V. A.; LUMBRERAS J.F.; COELHO M. R.; ALMEIDA J.A.; ARAÚJO FILHO J.C.; OLIVEIRA J. B.; CUNHA T.J.F. Sistema brasileiro de classificação de solos. **Rev. and Exp**, 5. ed., p. 356 Brasília, DF: Embrapa; 2018.

SILVA, C. A. da; SCHMILDT, E. R.; SCHMILDT, O.; ALEXANDRE, R. S.; CATTANEO, L. F.; FERREIRA, J. P.; NASCIMENTO, A. L. Correlações fenotípicas e análise de trilha em caracteres morfoagronômicos de mamoeiro. **Revista Agro@mbiente on-line**, v. 10, n. 3, p. 217-227, julho-setembro, 2016.

SILVA, W.; SCHMILDT, E. R.; SCHMILDT, O.; FERREGUETTI, G. A. Dimensionamento amostral para frutos de mamoeiro 'Golden THB' destinados ao mercado nacional e à exportação. **Revista Agro@ambiente On-line**, v.11, n.2, p.155- 163, 2017.

SILVA, C. A.; NASCIMENTO, A. L.; FERREIRA, J.P.; SCHMILDT, O.; MALIKOUSKI, R.G.; ALEXANDRE, R.S.; FERREGUETTI, G.A.; SCHMILDT, E.R. Genetic diversity among papaya accessions. **African Journal of Agricultural Research**, v.12, p.2041-2048, 2017.

SILVA, F.F. **Abordagem clássica e molecular do melhoramento genético do mamoeiro (Carica papaya L.)**. Tese (Doutorado em Produção Vegetal) - Campos dos Goytacazes - RJ, Universidade Estadual do Norte Fluminense Darcy Ribeiro - UENF, p.147, 2006.

SILVA, F.F.; PEREIRA, M.G.; RAMOS, H.C.C.; DAMASCENO JÚNIOR, P.C.; PEREIRA, T.N.S.; VIANA, A.P.; HAHER, R.F.; FERREGUETTI, G.A. Estimation of genetic parameters related to morpho-agronomic and fruit quality traits of papaya. **Crop Breeding and Applied Biotechnology**. v.8, p.65-73, 2008.

SIMÃO, S. **Tratado de fruticultura**. Piracicaba: FEALQ, p.541-572, 1998.

SOIL SURVEY STAFF. Keys to soil taxonomy. **Department of Agriculture, Natural Resources Conservation Service**. ed.12, p. 372. Washington, DC: United States, 2014.

SOUZA, L. G. de S. e; NETO, R. de C. A.; SILVA, N. M. da; UCHÔA, T. L.; Avanços na Propagação e Cultivo do Mamoeiro. **Applied Research & Agrotechnology**, Guarapuava-PR, v.13: e5949, 2020.

VETTORAZZI, J. C. F. **Linhagens Endogâmicas Recombinantes: Variabilidade Genética, Avaliação Per Se, Capacidade Combinatória e Heterose em Mamoeiro** (Tese de doutorado) Universidade Estadual do Norte Fluminense Darcy Ribeiro – UENF Campos dos Goytacazes – RJ, p. 91, 2020.

YAMANISHI, O.K.; MELLO, R.M. DE; MARTINS, V.A.; LIMA, L.A. DE; FAGUNDES, G.R.B. Comportamento do mamoeiro Sekati nas condições do oeste da Bahia. **Rev. Bras. Frutic.** v.28 n.1 Jaboticabal abr. 2006.

## **ARTIGO II**

### **MODELOS DE REGRESSÃO PARA ESTIMATIVA DA PRODUTIVIDADE DO MAMOEIRO**

## MODELOS DE REGRESSÃO PARA ESTIMATIVA DA PRODUTIVIDADE DO MAMOEIRO

**RESUMO:** Os reflexos do desenvolvimento da planta interferem diretamente sobre a produtividade, tornando-se, necessários estudos com entendimento relacionados aos atributos relevantes para a produtividade e para o planejamento agrícola. Dentro dessa perspectiva, os modelos biomatemáticos são promissores na predição da produtividade do mamoeiro. Objetivou-se com este estudo estimar a produtividade do mamoeiro CNPMF-L78, por meio da análise de regressão. Foram avaliadas 352 plantas em uma área útil de 2.112 m<sup>2</sup>, com os descritores da planta e os caracteres relacionados à qualidade do fruto. Foram ajustados modelos de regressão linear simples, apenas com efeitos simples para as variáveis explicativas e, regressão múltipla. A partir deste último modelo citado foi obtido um modelo reduzido pelo descarte dos efeitos menos relevantes, por meio da metodologia Stepwise. A análise das características vegetativas, por meio de adoção da regressão linear múltipla ou somente com as variáveis pelo emprego da regressão linear simples, permitiram a predição da produtividade em mamoeiro com maior assertividade para fomentar o aporte aos produtores por meio do planejamento agrícola.

**Palavras-chave:** *Carica papaya*, Modelagem, Predição, Produtividade



## REGRESSION MODELS FOR ESTIMATING PAPAYA PRODUCTIVITY

**ABSTRACT:** The reflections of plant development interfere directly on productivity, making necessary studies with understanding related to the relevant attributes for productivity and for agricultural planning. Within this perspective, biomathematical models are promising in predicting the productivity of papaya. The objective of this study was to estimate the productivity of papaya CNPMF-L78, by means of regression analysis. A total of 352 plants were evaluated in a usable area of 2,112 m<sup>2</sup>, with the plant descriptors and the characters related to fruit quality. Simple linear regression models were adjusted, with only simple effects for the explanatory variables and, multiple regression. From the latter model, a reduced model was obtained by discarding the less relevant effects, using the Stepwise methodology. The analysis of the vegetative characteristics, through the adoption of multiple linear regression or only with the variables by the use of simple linear regression, allowed the prediction of productivity in papaya with greater assertiveness to encourage the contribution to producers through agricultural planning.

**Keywords:** *Carica papaya*, Modeling, Prediction, Productivity

## 1. INTRODUÇÃO

A cultura do mamoeiro *Carica papaya* L, tem mostrado potencial econômico em várias regiões brasileiras, seja para os grandes e médios produtores ou para a agricultura familiar. Para o aprimoramento da produção, fazem-se necessário, constantes pesquisas sobre o mamoeiro, principalmente, em regiões onde a cultura é incipiente (SOUZA et al., 2020).

A agricultura de precisão (AP) é uma inovação tecnológica que possibilita racionalizar o uso dos recursos naturais e insumos agrícolas, melhorando a eficiência no processo produtivo (DALZOTTO ARTUZO; FOGUESATTO; SILVA, 2017). Neste panorama é traçado um planejamento que inicia com a construção de um mapa de produtividade, com adoção de técnicas morfométricas não destrutiva durante o cultivo (GUIMARÃES et al., 2018, 2019).

Modelos biomatemáticos, para fins de predição, oferecem as soluções para driblar os percalços de identificação de caracteres observados que se relacionam diretamente com a produtividade (FERRAZ et al., 2017; HENRICHSEN et al., 2018; FARIA et al., 2020). Tais modelos buscam elucidar o desenvolvimento das culturas, simulando o comportamento em termos de crescimento de seus componentes, como folhas, grãos e frutos, com a proposta de ganhos em economia de tempo e na utilização de recursos, que será convertida em lucros para o produtor. Embora haja empenho na área, ainda é baixa a precisão seletiva para análise do comportamento vegetal e seus reflexos sobre a produtividade. Em razão disto os modelos preditivos mais refinados é uma tendência na estimativa em produtividade.

Diante do exposto a análise de Regressão Linear Simples (RLS) (BERTOLIN et al., 2017), Múltipla (RLM) (SOARES et al., 2014; MANTAI et al., 2021), como modelo de predição poderá ser utilizada para elucidar questões quanto caracterização do mamoeiro, como meio de prevê a produtividade, tais como: explicar quais variáveis fenotípicas estão relacionadas à variável produtividade, assim como entender seu relacionamento, além de prever valores desconhecidos com antecedência à colheita, o que favorece o planejamento agrícola.


A estimativa de precisão é o alicerce para o delineamento estratégico em planejamento agrícola no que se refere a produção, vendas ou finanças. Portanto, este estudo, tem por finalidade ajustar por meio de interface de Regressão Linear Simples e Múltipla, modelos para predição da produtividade do mamoeiro CNPMF- L78.

## 2. MATERIAL E MÉTODOS

### 22.1. Implantação e condução da cultura do mamoeiro (Linhagem CNPMF-L78)

O estudo foi conduzido na Embrapa Mandioca e Fruticultura, no período de agosto de 2015 a março de 2017, em Cruz das Almas (BA), situado nas coordenadas geográficas: 12°40'39" latitude sul e 39°06'23" longitude oeste de Greenwich e altitude de 226 m, com temperatura média de 24,5 °C, umidade relativa de 82% e precipitação média anual de 1.197 mm (IBGE, 2020).

As características climáticas médias registradas no período do experimento (Figuras 1) foram obtidas no Posto Meteorológico da Embrapa Mandioca e Fruticultura, localizado próximo à área experimental.



Fonte: Estação Meteorológica da Embrapa Mandioca e Fruticultura (2020).

**Figura 1.** Características climáticas médias registradas entre agosto de 2015 e março de 2017, na área experimental da Embrapa Mandioca e Fruticultura em Cruz das Alma- BA.

O solo da área experimental é do tipo Latossolo Amarelo distrófico típico (SANTOS et al., 2018), que corresponde a um Ferralsol (IUSS WORKING GROUP WRB, 2015) ou um Oxisol (SOIL SURVEY STAFF, 2014). Para a correção e adubação do solo, seguiram-se as recomendações para a cultura do mamoeiro (OLIVEIRA; SOUZA; COELHO, 2010), sendo utilizadas na semeadura três sementes por saco plástico preenchidos com terra vegetal.

As sementes utilizadas no plantio foram da Linhagem CNPMF-L78, grupo Solo, provenientes do Banco Ativo de Germoplasma de Mamão (BAG-Mamão) da Embrapa Mandioca e Fruticultura.

Foram semeadas três sementes por saco plástico de polietileno com dimensões de 7,0 cm x 18,5 cm x 0,006 cm, correspondentes à largura, à altura e à espessura,

respectivamente. Preenchidos com substrato composto por solo, areia e esterco de curral curtido, na proporção de 3:1:1.

O desbaste foi efetuado aos 15 dias após a emergência das plantas, de forma a manter uma planta por saco plástico. E após 40 dias foram transplantadas para área experimental com adubação orgânica (esterco), com três plantas por cova e no início do florescimento das plantas foi mantida apenas uma planta a que apresentava inflorescências hermafroditas.

A área plantada foi constituída por 18 fileiras com 24 plantas cada e consideradas como útil as 16 fileiras centrais, com 22 plantas por fileira, no espaçamento de 3 m x 2 m, com o total de 352 plantas e área útil de 2.112 m<sup>2</sup>, não avaliando a primeira e a última planta de cada fileira.

## **2.2. Características morfoagronômicas avaliadas**

Foram avaliados 17 caracteres agronômicos, três relacionados às características vegetativas da planta, sete relacionados as reprodutivas e sete as de qualidade dos frutos, descritas a seguir:

### **2.2.1. Características vegetativas**

a. Altura da planta (AP6); (AP12); (AP18): distância entre a superfície do solo até o ponto de inserção da folha mais nova, localizado no ápice caulinar, avaliada aos seis, 12 e 18 meses de idade, expressa em centímetros (cm);

b. Altura de inserção dos primeiros frutos (AIPF): altura de inserção da primeira flor funcional (que irá produzir frutos), no início da produção, de oito a 10 meses após o plantio, a partir da superfície do solo, contígua ao colo da planta, até o ponto de inserção do primeiro fruto, expressa em centímetros (cm);

c. Diâmetro do caule (DC6); (DC12); (DC18): medido a 20 cm acima do nível do solo, avaliada aos seis, 12 e 18 meses de idade;

### **2.2.2. Caracteres reprodutivos**

a. Precocidade (PREC): avaliada mediante indicação da data da primeira colheita de frutos;

- b. Número de frutos comerciais por planta (NFC9); (NFC14): contagem de frutos comerciais presentes em cada planta aos nove e 14 meses após o plantio;
- c. Número de frutos comerciais totais (NFCT): soma de frutos comerciais presentes em cada planta aos nove e 14 meses após o plantio;
- d. Número de frutos deformados por planta (NFD9); (NFD14): contagem de frutos carpelóides, pentândricos e bananiformes presentes em cada planta, aos nove e 14 meses após o plantio;
- e. Número de nós sem frutos (NNSF9); (NNSF14): avaliado aos nove e 14 meses após o plantio, na região denominada usualmente por “pescoço”, mediante contagem do número de nós que não produziram frutos;
- f. Produtividade (PROD): Estimada pela multiplicação do número de frutos comerciais por planta (NFC) pelo peso médio do fruto por planta, considerando-se o espaçamento do plantio;

### **2. 2. 3. Caracteres de qualidade do fruto**

- a. Comprimento de fruto (CF): expresso em cm, com o auxílio de um paquímetro de madeira mediu-se o comprimento da base ao ápice do fruto;
- b. Diâmetro de fruto (DF): expresso em centímetros cm, com o auxílio de um paquímetro de madeira realizou-se a medição na parte de maior diâmetro do fruto;
- c. Massa de fruto (PF): expresso em gramas, pesou-se os frutos colhidos por planta em uma balança analítica. Os frutos foram colhidos no estágio 2 de maturação, ou seja, ¼ maduro, com até 25% da casca amarela;
- d. Teor de sólidos solúveis (SS): expresso em o Brix (°Bx), obtido com auxílio de refratômetro digital portátil modelo r2mini Reicher;
- e. Firmeza do fruto (FF): expresso em  $\text{kg cm}^{-2}$ , determinada em frutos maduros íntegros na região central com auxílio de um eletrômetro, a partir de 03 (três) leituras;
- f. Diâmetro da cavidade interna do fruto (DCI): expresso em cm, mediu-se o diâmetro da cavidade na parte central do fruto. No caso de cavidades em formato de estrela, as medidas foram tomadas de uma extremidade a outra de maior de distância;

- g. Espessura da polpa (EP): expresso em cm, com o auxílio de um paquímetro tomou-se a medição da espessura da polpa de maior tamanho após o corte transversal do fruto.

## 2.4. Modelagem

### 2.4.1. Modelo de regressão Linear Simples para predição da produtividade do mamoeiro

Foi considerado o modelo completo  $PM_i = \beta_0 + \beta_1 AP_{12i} + \beta_2 DC_{12i}^2 + \beta_3 AP_{18i} + \beta_4 DC_{18i}^2 + e_i$ . Onde  $AP_i$  e  $DC_i$  referem-se ao  $i$ -ésimo valor observado para a altura da planta e o diâmetro do caule, respectivamente.

### 2.4.2. Modelos de Regressão Múltipla

Modelos de regressão múltipla apenas com efeitos simples para as variáveis explicativas: ("Eq.  $i = \beta_0 + \beta_1 AP_6 + \beta_2 AP_{12} + \beta_3 AP_{18} + \beta_4 DC_{12} + \beta_5 DC_{18} + \beta_6 NFC_9 + \beta_7 NFC_{14} + e_i$ ;  $Y = \beta_0 + \beta_1 AP_6 + \beta_2 AP_{12} + \beta_3 AP_{18} + \beta_4 NFC_9 + \beta_5 NFC_{14} + e_i$ "). A fim de eliminar os parâmetros que menos contribuíram para o ajuste, garantido a obtenção de modelos parcimoniosos, utilizou-se a metodologia *stepwise*, com o auxílio da função *step* do software R. Esta metodologia exclui os parâmetros do modelo um a um a fim de obter menores valores do critério de informatividade de Akaike (AIC). O processo é feito de forma iterativa até que nenhum parâmetro excluído proporcione a redução do AIC (melhoria da qualidade do ajuste).

Para a seleção dos modelos de regressão, adotaram-se os critérios essenciais para a verificação da qualidade de ajuste com base na proposta de *Rencher e Schaalje* (2008): coeficiente de determinação ( $R^2$ ), coeficiente de determinação ajustado ( $R^2_{aj}$ ), seguido dos pressupostos da análise de regressão - a significância dos coeficientes, normalidade dos resíduos e a análise gráfica dos resultados. Considerou-se também o Critério de Informação de Akaike (AIC) (AKAIKE, 1974), o Critério de Informação Bayesiano (BIC) e o critério da seleção definido pelo loglike, que representa o valor do logaritmo da função de verossimilhança considerando-se as estimativas dos parâmetros. Os dados foram analisados pelo software R (R Development Core Team, 2016).

### 3. RESULTADOS E DISCUSSÃO

#### 3.1. Correlação

O rendimento do mamoeiro CNPMF-L78 apresentou correlação significativa com a maioria das características analisadas. Na Tabela 1, encontram-se as variáveis que se destacaram com boas estimativas das correlações de Pearson. Justificando, dessa forma, o emprego destas variáveis como preditoras da produtividade. Além da capacidade preditiva, as variáveis que compõem os modelos apresentados têm como vantagem a mensuração direta no campo de forma não destrutiva (GUIMARÃES et al., 2018, 2020).

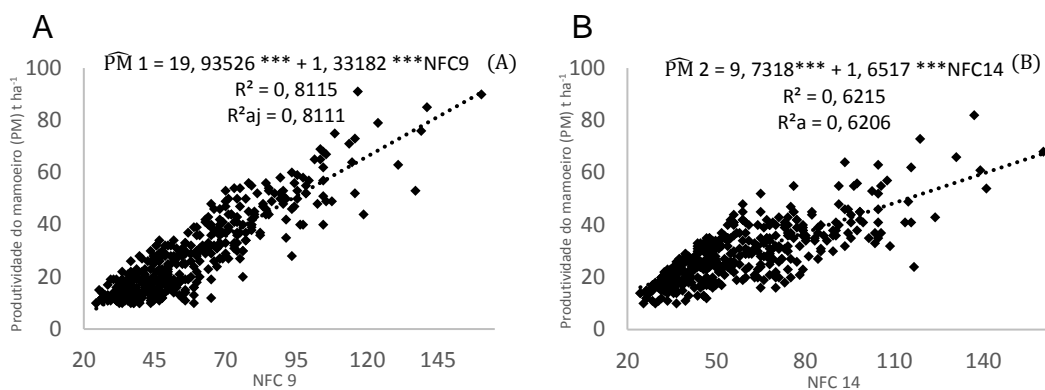
**Tabela 1.** Estimativa das correlações de Pearson entre características mensuradas manualmente.

CARACTERES	AP6	DC6	NFC9	AP12	DC12	NFC14	AP18	DC18
PROD	0,56	0,57	0,90	0,53	0,65	0,79	0,57	0,66
AP6		0,84	0,58	0,64	0,64	0,33	0,61	0,60
DC6			0,63	0,52	0,63	0,29	0,51	0,61
NFC9				0,45	0,55	0,44	0,47	0,57
AP12					0,74	0,44	0,79	0,68
DC12						0,56	0,74	0,87
NFC14							0,51	0,56
AP18								0,76

AP: Altura da planta; DC: diâmetro do caule (avaliados aos 6, 12 e 18 meses de idade); NFC: números de frutos comerciais (avaliados aos 9 e 14 meses);<sup>ns</sup> -Não significativo ( $p > 0.05$ ); \* - significativo ( $0.01 < p \leq 0.05$ ); \*\* - significativo ( $p \leq 0.01$ ) pelo teste t.

#### 3. 2. Regressão linear simples

Ajustou-se uma função para estimar a produtividade do mamoeiro, conforme os modelos:  $\widehat{PM} 1 = 19.93526^{***} + 1.33182^{***} NFC9$ ,  $R^2 = 0.8115$  (Figura 1A),  $AIC = 3355.66$  e  $\widehat{PM} 2 = 9.7318^{***} + 1.6517^{***} NFC14$ ,  $R^2 = 0.6587$  (Figura 2B),  $AIC = 3669.45$ . A qualidade do modelo (RLS) para predição do rendimento a partir do número de frutos comerciais foi testada com alta significância dos coeficientes de regressão ( $p < 0.0001$ ) e similaridade entre o  $R^2$  e o  $R^2$  ajustado, conforme apresentado nas Figuras 1A e 1B.



**Figura 1.** Estimativa da produtividade e a qualidade do ajuste pela variável preditiva números de frutos comerciais aos nove meses (A) e números de frutos comerciais aos 14 meses (B) para o mamoeiro CNPMF-L78.

Os modelos preditivos permitem descrever a produtividade de forma prática e objetiva no campo, pois contemplam apenas uma variável explicativa de fácil determinação. Contudo, além do melhor ajuste do  $R^2$ , o estimador (PM 1) aglomera maior qualidade preditiva pelo critério de informação AIC quando comparado ao modelo (PM 2). Esses dados obtidos evidenciam potencial preditivo para a característica números de frutos comerciais mensurado aos nove meses de idade.

Modelos compostos por variáveis de fácil mensuração em nível de campo são rebuscados por assegurar a aplicabilidade prática, favorecendo o uso da ferramenta preditiva com a inserção de valores de uma variável de mensuração direta na lavoura, especialmente como o observado para o modelo de regressão linear simples com a variável número de frutos comerciais aos nove meses (Figura 1A).

Neste contexto, Canal (2019) ajustou modelos de regressão linear para auxiliar na determinação das variáveis que mais explicam a variação na produção de frutos por planta em *Euterpe edulis*, o modelo mais parcimonioso observado dentre todos os modelos gerados expôs ajuste de  $R^2$  (0,89). Dentro deste âmbito de discussão modelos de regressão indicam que as variáveis explicativas ajudam a prever a ocorrência da variável dependente (FERNANDES et al., 2020).

### 3. 3. Regressão Linear Múltipla

Pela análise de regressão com a função linear múltipla testaram-se modelos para estimar a produtividade do mamoeiro CNPMF-L78, conforme os resultados apresentados na Tabela 1. O teste t para os modelos de regressão foi altamente significativo ( $p < 0.0001$ ), indicando ajuste adequado desses modelos aos dados fitotécnicos.



**Tabela 2.** Parâmetros da análise de regressão linear múltipla da variável de rendimento como função das características: Altura da planta; Diâmetro do caule e Número de frutos comerciais (AP6; DC6; NFC9; AP12; DC12; NFC14; AP18 E DC18). AIC: Critério de informação de Akaike; BIC: Critério de informação de Bayesiano; R<sup>2</sup>: Coeficiente determinação ajustado.

Modelos	Stepwise	Ajuste modular			R <sup>2</sup>	R <sup>2</sup> a
	AIC	AIC	BIC	Log lik		
PM 3 = AP6 + DC6 + NFC9 + AP12 + DC12 + NFC14 + AP18 + DC18	-5260.15	-	-	-	-	-
PM 4 = AP6 + DC6 + NFC9 + AP12 + NFC14 + AP18 + DC18	-5262.06	-	-	-	-	-
PM 5 = AP6 + DC6 + NFC9 + AP12 + NFC14 + DC18	-5263.88	-	-	-	-	-
PM 6 = AP6 + NFC9 + AP12 + NFC14 + DC18	-5265.6	-	-	-	-	-
PM 7 = AP6 + NFC9 + NFC14 + DC18	-5266.96	-	-	-	-	-
PM 8 = NFC9 + NFC14 + DC18	-5268.56	-	-	-	-	-
PM 9 = 0,0003454+1,0145951***NFC9+ 1,0145826***NFC14	-5269.06	-3990.019	-3973.582	1999.01	1	1

R<sup>2</sup> - Coeficiente de determinação; R<sup>2</sup>a - Coeficiente de determinação ajustado

Tanto pelo método *Stepwise* quanto pelo teste de redução sequenciada os indicadores de qualidade AIC, BIC e Log Lik qualificaram o modelo PM 9 = 0,0003454 + 1,0145951 \*\*\* NFC9 + 1,0145826 \*\*\* NFC14 com maior potencial na predição da produtividade do mamoeiro com R<sup>2</sup> de 1.00 e R<sup>2</sup><sub>aj</sub> = 1.00 (Tabela 1).

Contudo, para os modelos testados, o coeficiente de determinação se manteve com a mesma qualidade de ajuste (Figura 1), apesar de ter subtraído as variáveis vegetativas com moderada e alta correlação com a produção (Tabela 1), mas, com efeito não significativo para compor o modelo, como o número de frutos comerciais (9) e o número de frutos comerciais (14), (Tabela 2).

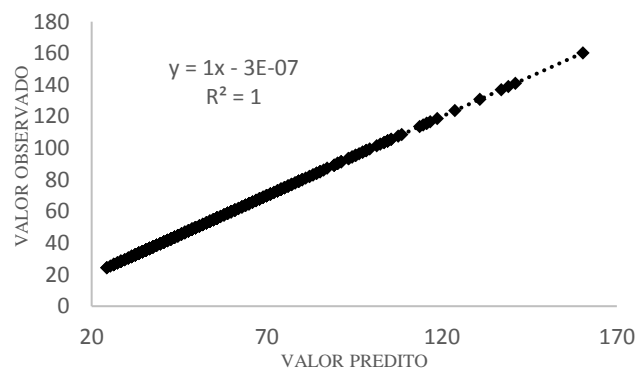
Em maracujazeiro-amarelo, Nunes (2020) validou modelos para a estimar a produtividade de frutos comerciais em função de diferentes doses de nitrogênio com a associação das variáveis significativas, com ajuste de R<sup>2</sup> = 0,97. Os resultados tiveram efeito positivo e similar nas características de produção de frutos comerciais e diâmetro do caule na produtividade e na qualidade físico-química do maracujazeiro-amarelo.

Com base nos parâmetros estatísticos que indicam precisão, apresentados na Tabela 2, e no comportamento das equações que estimam a produtividade por meio do modelo de regressão linear múltipla foi possível predizer de forma aceitável a produtividade do mamoeiro com as variáveis reprodutivas NFC9 e NFC14. Essas variáveis submetidas às técnicas de regressão são de simples determinação em campo (HUANG et al., 2020; HE et al., 2020), o que favorece a eficiência da capacidade

preditiva do modelo, tornando-se uma ferramenta confiável para aplicação em identificar características com potencial produtivo antes da época de colheita.

As Figuras 1A e 1B representam a relação simples entre a produtividade do mamoeiro e as variáveis predictoras NFC9 e NFC14, respectivamente, o que indica que esses atributos possuem grande sensibilidade para expressar a produtividade. Para atestar a qualidade do modelo de regressão linear múltipla com as citadas variáveis simultaneamente, relacionou-se, na Figura 2, os valores preditos aos valores observados, obtendo, dessa forma, a máxima capacidade preditiva, com ajuste entre os dados com valor igual a 1.

Esse procedimento se justifica tanto pelo viés estatístico em busca dos parâmetros altamente significativos, quanto pela necessidade de se obter um modelo mais consistente e robusto. Neste contexto, Rego; Araújo e Sousa Neto (2020) acrescentam que o modelo é um recurso que pode possibilitar um melhor planejamento agrícola a fim de reduzir custos e facilitar o desenvolvimento das atividades dos agricultores.



**Figura 2.** Qualidade do ajuste definida pelo modelo  $PROD = 0,0003454 + 1.0145951^{***}NFC9 + 1.0145826^{***}NFC14$  para estimativa da produtividade do mamoeiro por regressão linear múltipla com as variáveis NFC9 e NFC14.

Ainda, com relação ao ajuste dos modelos de regressão expresso pelo coeficiente de determinação -  $R^2$  não se observou diferença entre as equações (Tabela 1). Contudo, o modelo  $PM 9 = 0,0003454 + 1.0145951^{***}NFC9 + 1.0145826^{***}NFC14$  por estar conectado exclusivamente a dois descritores relacionados diretamente a produtividade (NFC9 e NFC14.), torna-se mais simplificado, adequado e confiável.

Quanto aos parâmetros que definem a qualidade do ajuste da equação, os menores valores estimados foram associados ao modelo PM 9, portanto, definido como

mais adequado (Tabela 2), por apresentar a maior proximidade entre os valores observados e os estimados. Leal et al. (2015) e Mello et al. (2018) argumentam sobre a importância das ferramentas que aferem a precisão do modelo para consubstanciar a seleção na prática, para que assim resultados satisfatórios sejam obtidos.

Os estimadores de ajustes, AIC, BIC e logLik, estão de conformidade com a soma dos quadrados dos erros. Assim sendo, quanto menor o valor desse parâmetro, associado a um modelo menor, sua divergência predita e, conseqüentemente a qualidade do ajuste, será definida pela menor distância relativa entre os valores preditos e os reais, sendo esses critérios de suma importância para a modelagem matemática (LEAL et al., 2015; GOMES et al., 2018).

Dadas estas considerações, os parâmetros citados, associado à obtenção dos dados de forma não destrutiva propicia ao profissional da área, maior confiança para estimar a produtividade do mamoeiro CNPMF-L78 por meio da análise de regressão. Portanto, a técnica de regressão pode ser facilmente implementada no monitoramento e estimativa de colheitas em diferentes culturas (GUIMARÃES et al., 2020), por fácil explicação da relação entre uma variável dependente e uma ou mais variáveis explicativas, o que possibilita conhecer de forma eficiente e prévia os valores da variável de interesse (MANTAI et al., 2021).

Considerando que, um dos principais componentes do custo de produção do mamão é a utilização de máquinas e implementos agrícolas para as operações de preparo do solo, do plantio, da adubação, da pulverização e da colheita, faz se necessário a utilização de ferramentas que permita a redução dos custos de produção, propicie melhor planejamento e rentabilidade (PÁDUA, 2019). Assim, a estimativa da produtividade do mamoeiro, reveste-se de grande importância, por possibilitar predizer o desenvolvimento de práticas que demande menores custos, possibilitando melhor tomada de decisão ao produtor e conseqüentemente maior rendimento.

Para predição da produtividade em mamoeiro CNPMF-L78, embora o modelo múltiplo seja composto por maior número de parâmetros preditivos, as variáveis são de fácil determinação em nível de campo, o que assegura a viabilidade prática, conforme se têm valorizado nos estudos sobre a modelagem agrícola (MELLO et al., 2018; GUIMARÃES et al., 2018, 2020).

#### 4. CONCLUSÃO

A análise das características reprodutivas números de frutos comerciais aos nove e 14 meses, tanto na regressão linear simples com as variáveis isoladas, quanto na regressão múltipla em combinação destas, permitem a predição da produtividade do mamoeiro de modo prático, simples e eficiente.

#### REFERÊNCIA

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, v.19, p.716-723, 1974.

BERTOLIN, N. de O.; Filgueiras, R.; Venancio, L. P.; Mantovani, E. C. Predição da produtividade de milho irrigado com auxílio de imagens de satélite. **Revista Brasileira de Agricultura Irrigada**, v.11, p.1627-1638, 2017.

CANAL, B. G. **Melhoramento Genético de *Euterpe Edulis* para Produção de Frutos** (dissertação). Universidade Federal do Espírito Santo Centro de Ciências Agrárias e Engenharias Programa de Pós-Graduação em Produção Vegetal. Alegre, ES, p.64, 2019.

DALZOTTO ARTUZO, F.; FOGUESATTO, C. R.; DA SILVA, L. X. Agricultura de precisão: inovação para a produção mundial de alimentos e otimização de insumos agrícolas. **Revista Tecnologia e Sociedade**, v.13, n.29, p. 146-161, 2017.

DONATO, P. E. R.; Donato, S. L. R.; Silva, J. A.; Pires, A. J. V.; Silva Júnior, A. A. Extraction/exportation of macronutrients by cladodes of 'Gigante' cactus pear under different spacing and organic fertilizer. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.21, n.4, p.238-243, 2017.

FARIA, G. A.; COSTA, T. F.; FELIZARDO, L. M.; LOPES, B. G.; OLIVEIRA, C. P. M. de; LIMA, J. F. de; FONSECA, A. D. da; ROCHA, P. S.; PEIXOTO, A. P. B.; OLIVEIRA, T. A. de. Regressão com platô na estimação do tamanho ótimo de parcelas em experimentos com mamoeiro em casa de vegetação. **Research, Society and Development**, v.9, n.10, e9159109289, 2020.

FERNANDES, A. A. T.; FILHO, D. B. F.; ROCHA, E. C. da; Nascimento, W. da S. Leia este artigo se você quiser aprender regressão logística. **Revista de Sociologia e Política**. v.28, n.74, e006, 2020.

FERRAZ, G. A. e S.; OLIVEIRA, M. S.; SILVA, F. M. da. AVELAR, R. C.; SILVA, F. C.; FERRAZ, P. F. P. Methodology to determine the soil-sampling grid for precision agriculture in a coffee field. **DYNA**, v.84, n.200, p.316-325, 2017.

GOMES, F.P.; RESENDE, O.; SOUSA, E.P.; OLIVEIRA, D.E.C.; ARAÚJO NETO, F.R. Drying kinetics of crushed mass of 'jambu': Effective diffusivity and activation energy. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.22, n.7, p.499-505, 2018.

GUIMARÃES, B. V. C.; DONATO, S. L. R.; AZEVEDO, A. M.; ASPIAZÚ, I.; SILVA JUNIOR, A. A. e. Prediction of 'Gigante' cactus pear yield by morphological characters and artificial neural networks. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.22, n.5, p.315-319, 2018.

GUIMARÃES, B. V. C.; DONATO, S. L. R.; ASPIAZÚ, I.; AZEVEDO, A. M.; CARVALHO, A. J. Comparison of Methods for Harvest Prediction in 'Gigante' Cactus Pear. **Journal of Agricultural Science**, v.11, n.14, 2019.

GUIMARÃES, B. V. C.; DONATO, S. L. R.; ASPIAZÚ, I.; AZEVEDO, A. M.; CARVALHO, A. J. Regression models for productivity prediction in cactus pear cv. Gigante. **Revista Brasileira de Engenharia Agrícola e Ambiental** v.24, n.11, p.721-727, 2020.

HUANG, Y.; REN, Z., Li, D.; LIU, X. Técnicas fenotípicas e aplicações em fruteiras: uma revisão. **Plant Methods**, v.278, artigo: 10987316, 2020.

HE, Z.; XIONG, J.; CHEN, S.; LI, Z.; CHEN, S.; ZHONG, Z.; YANG, Z. Um método de detecção de cítricos verdes com base em uma floresta de regressão de caixa delimitadora profunda. **Biosystems Engineering**, v.193, p.206-215, 2020.

HENRICHSEN, L.; MAROLLI, A.; MANTAI, R. D.; SCREMIN, O. B.; REGINATTO, D. C.; ARENHARDT, L. G.; BANDEIRA, L. M.; MATTER, E. M.; PEREIRA, E. A.; SILVA, J. A. G. da. Regressão linear múltipla a simulação da produtividade de biomassa a elaboração de silagem por variáveis meteorológicas com nitrogênio e regulador de crescimento. **IN: XXXVIII Reunião Brasileira da pesquisa de aveia**. Universidade Regional- UNIJUÍ, 20 a 22 de março. Ijuí, RS, 2018.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Cidades e estados**. 2909802. Cruz das Almas- BA, 2020. Disponível em: <https://cidades.ibge.gov.br/brasil/ba/cruz-das-almas/coordenadas>. Acessado em: 22.07.2021.

IUSS Working Group WRB. World reference base for soil resources 2014, update 2015. **International soil classification system for naming soils and creating legends for soil maps**. Rome: FAO; 2015. (World Soil Resources Reports, 106).

LEAL, A. J. F.; Miguel, E. P.; Baio, F. H. R.; Neves, D. de C.; Leal, U. A. S. Redes neurais artificiais na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do solo. **Bragantia**, v.74, p.436-444, 2015.

MANTAI, R. D.; SILVA, J. A. G. da; CARBONERA, R.; CARVALHO, I. R.; LAUTENCHLEGER, F. PEREIRA, L. M. Eficiência técnica e agrônômica do nitrogênio na produtividade e qualidade de grãos de aveia. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.25, n.8, p.529-537, 2021

MELLO, M. N. de; DIAS, C. T. dos S.; MARTORANO, L. G.; CHAVES, S. S. de F.; FERNANDES, P. C. C. Modelos não lineares mistos para descrever o teor de carbono orgânico no solo. **Revista Brasileira de Biometria**, v.36, n.1, p.230-240, 2018.

MORAES, R. **Parâmetros genéticos e repetibilidade para resistência de genótipos de mamoeiro a Pinta-Preta em sucessivas avaliações** (Dissertação) Universidade Estadual do Norte Fluminense Darcy Ribeiro – UENF Campos dos Goytacazes – RJ, 56p, 2018.

NUNES, R. T. C. **Adubação nitrogenada no crescimento e na qualidade de frutos de maracujazeiro amarelo** (tese doutorado). Vitória da Conquista BA, p.140, 2020.

OLIVEIRA, A. M. G.; COELHO, E. F. Calagem e adubação para mamoeiro. In.: **BORGES, A. L. e SOUZA, L. S.** Recomendações de calagem e adubação para abacaxi, acerola, banana, laranja, tangerina, lima ácida, mamão, mandioca, manga e maracujá. Embrapa Mandioca e Fruticultura, Cruz das Almas, p.108-125, 2009.

PÁDUA, T. R. P. de. **Plano estratégico para a cultura do mamoeiro: 2017-2021.1** / Editor técnico, Cruz das Almas, BA: Embrapa Mandioca e Fruticultura (Documentos/ Embrapa Mandioca e Fruticultura, ISSN 1809-4996.228) 32 p. il. 21 cm, 2019.

R Development Core Team. **The R Project for Statistical Computing**. 2016. Disponível em: <<https://www.r-project.org/>>. Acesso em: junho de 2021.

RENCHER, A. C.; Schaalje, G. B. Linear models in statistics. New Jersey: **John Wiley & Sons**, 663p. 2008.

REGO, N. G.; ARAUJO, D. P. de; SOUSA NETO, J. V. de. Aplicação de modelo estatístico para estimativa da produção de soja na região de Balsas- MA. **Revista Científica**, Faculdade de Balsas, v.11, n.1, p.74-79, 2020.

SANTOS HG, JACOMINE PKT, ANJOS LHC, OLIVEIRA VA, LUMBRERAS JF, COELHO MR, ALMEIDA JA, ARAÚJO FILHO JC, OLIVEIRA JB, CUNHA TJF. Sistema brasileiro de classificação de solos. **Rev. and Expliada**, 5. ed., p. 356 Brasília, DF: Embrapa; 2018.

SOARES, J. D. R.; Pasqual, M.; Lacerda, W. S.; Silva, S. O.; Donato, S. L. R. Comparison of techniques used in the prediction of yield in banana plants. **Scientia Horticulturae**, v.167, p.84–90, 2014.

SOIL SURVEY STAFF. Keys to soil taxonomy. **Department of Agriculture, Natural Resources Conservation Service**. ed.12, p. 372. Washington, DC: United States, 2014.

SOUZA, L. G. de S. e; NETO, R. de C. A.; SILVA, N. M. da; UCHÔA, T. L.; Avanços na Propagação e Cultivo do Mamoeiro. **Applied Research & Agrotechnology**, Guarapuava-PR, v.13, e5949, 2020.

SOUZA, L. da S.; SOUZA, L.D. **Caracterização físico-hídrica de solos da área do Centro Nacional de Pesquisa de Mandioca e Fruticultura**. (Embrapa-CNPMPF. Boletim Técnico, 20). Cruz das Almas: Embrapa Mandioca e Fruticultura, p. 56, 2001.

### **ARTIGO III**

**PREDIÇÃO DE PRODUTIVIDADE DO MAMOEIRO (*Carica papaya* L.) POR REDES  
NEURAS ARTIFICIAIS**



## **PREDIÇÃO DE PRODUTIVIDADE DO MAMOEIRO (*CARICA PAPAYA L.*) POR REDES NEURAIS ARTIFICIAIS**

**RESUMO:** A estimativa da produtividade do mamoeiro é importante para o planejamento de produtores rurais, tornando-se uma ferramenta eficiente e estratégica na tomada de decisões da produção agrícola, sobretudo no que diz respeito ao planejamento de pós colheita, armazenamento e transporte. O objetivo desse estudo foi selecionar modelos de Redes Neurais Artificiais com maior capacidade preditiva da colheita para cultura do mamoeiro CNPMF-L78. Foram mensuradas 352 plantas em uma área útil de 2.112 m<sup>2</sup>, com os descritores de planta e os caracteres relacionados à qualidade do fruto. Os dados foram submetidos a análise por redes neurais artificiais, utilizando-se o software R. Os melhores ajustes para a estimativa da produtividade do mamoeiro foram considerados três camadas das RNAs: entrada, intermediária e a camada de saída, testando-se a composição com um a 10 neurônios na camada intermediária. Esses modelos apresentaram os menores erros quadráticos médios, o que corresponde a maior proximidade entre os dados preditos e os reais, e, por conseguinte, maior eficiência das redes na predição da produtividade. Pelo coeficiente de determinação, verificaram-se os melhores ajustes para caracteres reprodutivos  $R^2 = 0,99$ , os caracteres vegetativos proporcionaram  $R^2 = 0,54$ , enquanto que os caracteres de qualidade e rendimento viabilizou  $R^2 = 0,24$ . Previsões de produtividade para o mamoeiro CNPMF-L78 foram obtidas com alta eficiência para os caracteres reprodutivos por meio de redes neurais artificiais.

**Palavras-chave:** Inteligência artificial; mamão; planejamento rural; predição

## **PREDICTION OF PRODUCTIVITY OF PAPAYA (CARICA PAPAYA L.) BY ARTIFICIAL NEURAL NETWORKS**

**ABSTRACT:** The estimation of the productivity of papaya is important for the planning of rural producers, becoming an efficient and strategic tool in the decision making of agricultural production, especially with regard to post-harvest planning, storage and transportation. The objective of this study was to select Artificial Neural Network models with greater predictive capacity of the harvest for the papaya crop CNPMF-L78. A total of 352 plants were measured in a useful area of 2,112 m<sup>2</sup>, with the plant descriptors and the characters related to fruit quality. The data were submitted to artificial neural network analysis using the R software. The best fits for estimating the productivity of papaya were considered for three layers of ANNs: input, intermediate, and output layers, testing the composition with one to 10 neurons in the intermediate layer. These models presented the lowest mean square errors, which corresponds to greater proximity between predicted and actual data, and therefore greater efficiency of the networks in predicting yields. By the coefficient of determination, the best fits were verified for reproductive characters  $R^2 = 0.99$ , vegetative characters provided  $R^2 = 0.54$ , while quality and yield characters enabled  $R^2 = 0.24$ . Productivity predictions for CNPMF-L78 papaya were obtained with high efficiency for reproductive characters by means of artificial neural networks.

**Keywords:** Artificial intelligence; papaya; rural planning, prediction

## 1. INTRODUÇÃO

A estimativa precisa do rendimento é um dos propósitos buscado em cultivos de mamoeiro devido ao alto valor econômico de sua produção. O mamão (*Carica papaya* L.) tem grande importância para a agricultura e é amplamente cultivado nas regiões tropicais e subtropicais do mundo (MISHRA et al., 2021). Seu desempenho na agricultura brasileira, demanda novas técnicas, que busque eficiência em ganhos de produção. Todavia um dos problemas mais importantes da agricultura é a falta de previsão do rendimento da safra (PANT et al., 2021).

Impasse esse, que tem sido alvo em estudos nos programas de melhoramento com o desenvolvimento de variedades de alta produtividade e práticas que permitam reduzir o uso de defensivos e o custo de fertilizantes, priorizando a redução do custo de produção (EMBRAPA, 2020). Contudo, mesmo com os avanços nos programas de melhoramento, é de extrema necessidade técnicas mais robustas que possam fazer a predição de produtividade de forma mais eficiente possível.

Nesse sentido, técnicas de produção se alicerçam, cada vez mais, no aperfeiçoamento do uso dos insumos e nas metodologias destinadas a estimar a produção, de forma a melhorar a produtividade e a rentabilidade. O novo mercado agrícola digital tem como vantagem a digitalização, as plataformas digitais amplificam benefícios para vários setores agrícolas, auxiliando na melhor tomada de decisão (MERLADETE, 2021). Entretanto, o rendimento da agricultura depende de vários fatores, como condições climáticas, ambientais, de manejo e tratamentos culturais, o que dificulta a exata estimativa de produtividade (EMBRAPA, 2020).

Na direção em otimizar as atividades agrícolas, driblando os percalços associados à predição da produtividade, modelagens em Redes Neurais Artificiais têm se mostrado promissor. Pela relevância e necessidade de se conhecer a produtividade previamente, diversas culturas já desenvolveram modelos preditores da produtividade, como a cultura do milho (SOARES et al., 2015), palma forrageira (GUIMARÃES et al., 2018), de trigo (MAMANN et al., 2019), soja na região do Matopiba (SANTOS, 2020), bananeiras 'Prata-Anã' e 'BRS Platina' (GUIMARÃES et al., 2021).

Todavia, o mamoeiro carece de uma ferramenta precisa, que proponha menos tempo de análise, para que o produtor tenha maior prazo para o

planejamento, para assim assegurar um bom empreendimento. Dessa forma, os modelos heurísticos, ou seja, a Ciência da inteligência Computacional traz uma proposta que viabiliza os dados biométricos e propõem resultados mais rápidos, com menor margem de erro. Auxiliando o profissional da área quanto à tomada de decisão em uma produção já prevista.


Nesse sentido, este estudo teve por propósito selecionar modelos de Redes Neurais Artificiais com maior capacidade preditiva da colheita para cultura do mamoeiro CNPMF-L78.

## 2. MATERIAL E MÉTODOS

### 2.1. Implantação e condução da cultura do mamoeiro (Linhagem CNPMF-L78)

O estudo foi conduzido na Embrapa Mandioca e Fruticultura, no período de agosto de 2015 a março de 2017, em Cruz das Almas (BA), situado nas coordenadas geográficas: 12°40'39" latitude sul e 39°06'23" longitude oeste de Greenwich e altitude de 226 m, com temperatura média de 24,5 °C, umidade relativa de 82% e precipitação média anual de 1.197 mm (IBGE, 2020).

As características climáticas médias registradas no período do experimento (Figuras 1) foram obtidas no Posto Meteorológico da Embrapa Mandioca e Fruticultura, localizado próximo à área experimental.



Fonte: Estação Meteorológica da Embrapa Mandioca e Fruticultura (2020).

**Figura 1.** Características climáticas médias registradas entre agosto de 2015 e março de 2017, na área experimental da Embrapa Mandioca e Fruticultura em Cruz das Almas - BA.

O solo da área experimental é do tipo Latossolo Amarelo distrófico típico (SANTOS et al., 2018), que corresponde a um Ferralsol (IUSS WORKING GROUP WRB, 2015)) ou um Oxisol (SOIL SURVEY STAFF, 2014). Para a correção e adubação do solo, seguiram-se as recomendações para a cultura do mamoeiro (OLIVEIRA; SOUZA; COELHO, 2010), sendo utilizadas na semeadura três sementes por saco plástico preenchidos com terra vegetal.

As sementes utilizadas no plantio foram da Linhagem CNPMF-L78, grupo Solo, provenientes do Banco Ativo de Germoplasma de Mamão (BAG-Mamão) da Embrapa Mandioca e Fruticultura.

Foram semeadas três sementes por saco plástico de polietileno com dimensões de 7,0 cm x 18,5 cm x 0,006 cm, correspondentes à largura, à altura e à espessura, respectivamente. Preenchidos com substrato composto por solo, areia e esterco de curral curtido, na proporção de 3:1:1.

O desbaste foi efetuado aos 15 dias após a emergência das plantas, de forma a manter uma planta por saco plástico. E após 40 dias foram transplantadas para área experimental com adubação orgânica (esterco), com três plantas por cova e no início do florescimento das plantas foi mantida apenas uma planta a que apresentava inflorescências hermafroditas.

A área plantada foi constituída por 18 fileiras com 24 plantas cada e consideradas como útil as 16 fileiras centrais, com 22 plantas por fileira, no espaçamento de 3 m x 2 m, com o total de 352 plantas e área útil de 2.112 m<sup>2</sup>, não avaliando a primeira e a última planta de cada fileira.

## **2.2. Características morfoagronômicas avaliadas**

Foram avaliados 17 caracteres agronômicos, três relacionados às características vegetativas da planta, sete relacionados as reprodutivas e sete as de qualidade dos frutos, descritas a seguir:

### **2.2.1. Características vegetativas**

a. Altura da planta (AP6); (AP12); (AP18): distância entre a superfície do solo até o ponto de inserção da folha mais nova, localizado no ápice caulinar, avaliada aos seis, 12 e 18 meses de idade, expressa em centímetros (cm);

b. Altura de inserção dos primeiros frutos (AIPF): altura de inserção da primeira flor funcional (que irá produzir frutos), no início da produção, de oito a 10 meses após o plantio, a partir da superfície do solo, contígua ao colo da planta, até o ponto de inserção do primeiro fruto, expressa em centímetros (cm);

c. Diâmetro do caule (DC6); (DC12); (DC18): medido a 20 cm acima do nível do solo, avaliado aos seis, 12 e 18 meses de idade;

### **2.2.2. Caracteres reprodutivos**

a. Precocidade (PREC): avaliada mediante indicação da data da primeira colheita de frutos;

b. Número de frutos comerciais por planta (NFC9); (NFC14): contagem de frutos comerciais presentes em cada planta aos nove e 14 meses após o plantio;

c. Número de frutos comerciais totais (NFCT): soma de frutos comerciais presentes em cada planta aos nove e 14 meses após o plantio;

d. Número de frutos deformados por planta (NFD9); (NFD14): contagem de frutos carpelóides, pentândricos e bananiformes presentes em cada planta, aos nove e 14 meses após o plantio;

e. Número de nós sem frutos (NNSF9); (NNSF14): avaliado aos nove e 14 meses após o plantio, na região denominada usualmente por “pescoço”, mediante contagem do número de nós que não produziram frutos;

f. Produtividade (PROD): Estimada pela multiplicação do número de frutos comerciais por planta (NFC) pelo peso médio do fruto por planta, considerando-se o espaçamento do plantio;

### **2. 2. 3. Caracteres de qualidade do fruto**

a. Comprimento de fruto (CF): expresso em cm, com o auxílio de um paquímetro de madeira mediu-se o comprimento da base ao ápice do fruto;

b. Diâmetro de fruto (DF): expresso em centímetros cm, com o auxílio de um paquímetro de madeira realizou-se a medição na parte de maior diâmetro do fruto;

- c. Massa de fruto (PF): expresso em gramas, pesou-se os frutos colhidos por planta em uma balança analítica. Os frutos foram colhidos no estágio 2 de maturação, ou seja,  $\frac{1}{4}$  maduro, com até 25% da casca amarela;
- d. Teor de sólidos solúveis (SS): expresso em o Brix ( $^{\circ}\text{Bx}$ ), obtido com auxílio de refratômetro digital portátil modelo r2mini Reicher;
- e. Firmeza do fruto (FF): expresso em  $\text{kg cm}^{-2}$ , determinada em frutos maduros íntegros na região central com auxílio de um eletrômetro, a partir de 03 (três) leituras;
- f. Diâmetro da cavidade interna do fruto (DCI): expresso em cm, mediu-se o diâmetro da cavidade na parte central do fruto. No caso de cavidades em formato de estrela, as medidas foram tomadas de uma extremidade a outra de maior de distância;
- g. Espessura da polpa (EP): expresso em cm, com o auxílio de um paquímetro tomou-se a medição da espessura da polpa de maior tamanho após o corte transversal do fruto.

#### **2. 2. 4. Modelagem dos dados Redes Neurais Artificiais-RNA**

Os dados foram avaliados por Redes Neurais Artificiais (RNA) no software R. Para o treinamento das RNAs tanto os dados das variáveis preditoras (AP6; AP12; AP18; AIPF; DC6; DC12; DC18; PREC; NFC9; NFC14; NFCT; NFD9; NFD14; NNSF9; NNSF14; PROD; CF; DF; PF; SS; FF; DCI; EP) quanto os da variável predita (Produtividade) foram normalizados no intervalo entre 0 e 1 pela função *normalizeData* do pacote *RSNNS* (BERGMEIR; BENÍTEZ, 2012).

Na análise por RNAs, 80% dos dados (282 plantas) foram destinadas ao treinamento da rede, e 20% para a análise de validação (70 plantas). O conjunto de dados foi selecionado de modo aleatório para as duas amostras. O modelo neural empregado foi do tipo perceptron de multicamadas (MLP - *Multi-Layer-Perceptron*) com o auxílio dos pacotes Keras e tensorflow no software R. Para a estimativa da produtividade do mamoeiro foram considerados três camadas das RNAs: entrada, intermediária e a camada de saída, testando-se a composição com um a 10 neurônios na camada intermediária.

Foi considerada a função de ativação “sigmoide” para a camada intermediária e de saída. Na compilação do modelo foi utilizado o otimizador “rmsprop”, função de perda “mse” e taxa de aprendizado de 0,1. No treinamento foi arbitrado 500 épocas de treinamento, com as funções de ativação para as camadas intermediárias e de saída ajustadas como logística e linear, respectivamente. Posteriormente, a melhor arquitetura de rede, selecionada pelo menor erro quadrático médio na predição da amostra de validação, foi treinada por 1000 vezes.

Para avaliar a capacidade preditiva do modelo, os dados da produtividade predita e a observada na amostra de validação foram submetidos à análise de regressão. Assim, pela associação entre as variáveis preditas e observadas, testou-se a significância do coeficiente angular da reta pelo teste t. Dessa forma, se coeficiente angular da reta não se diferir de 1 e o coeficiente de determinação for alto, assume-se eficiência no processo de predição.

O coeficiente de determinação do modelo foi determinado por:

$$R^2 = \left( \frac{\sum_{i=1}^n (Xobs_i - \overline{Xobs})(Xpred_i - \overline{Xpred})}{\sqrt{\sum_{i=1}^n (Xobs_i - \overline{Xobs})^2 (Xpred_i - \overline{Xpred})^2}} \right)^2$$

O erro quadrático médio (EQM) foi estabelecido pela média entre diferença quadrática entre os valores observados e os previstos pelos modelos, em que o menor valor indicou o melhor ajuste do modelo. EQM para este estudo é definido pela seguinte expressão:

$$EQM = \sum_i^n \frac{(Xobs_i - Xpred_i)^2}{n}$$

Em que:

$Xobs_i$ : i-ésimo valor observado para a variável dependente;

$\overline{Xobs}$ : média do valor observado para a variável dependente;

$Xpred_i$ : i-ésimo valor predito para a variável dependente;


$\overline{Xpred}$ : média do valor predito para a variável dependente.



### 3. RESULTADOS E DISCUSSÃO

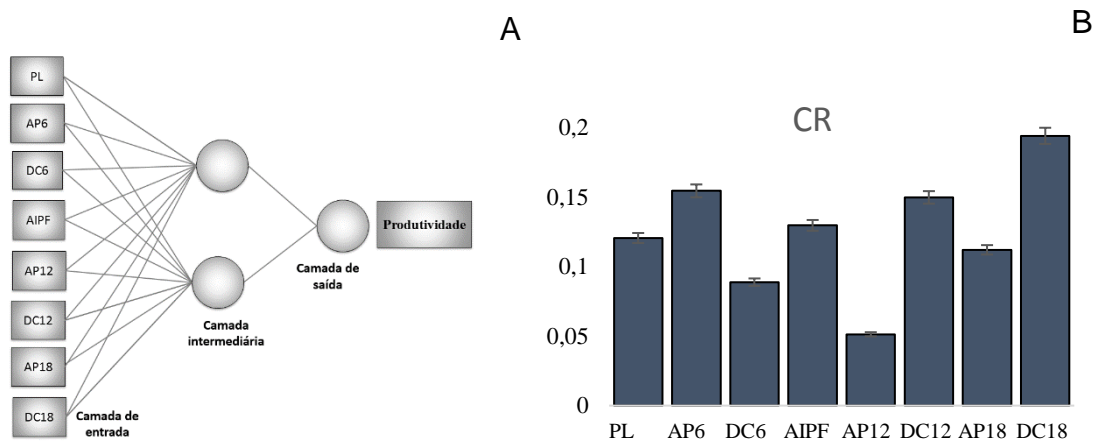
#### 3.1. Modelagem dos dados de RNA para as características vegetativas

O desempenho das arquiteturas de rede foi medido pelo erro quadrático médio (EQM) e os resultados mostram boa consistência na análise dos dados, como retratados na Figura 1, com a expressão do número de neurônios das camadas intermediárias, EQM (Figura 1A) e o coeficiente de determinação ( $R^2$ ) (Figura 1B). Após intenso treinamento para se obter uma rede adequada (SOARES et al., 2014), ficou estabelecido a melhor arquitetura da rede a que possibilitou menor erro quadrático médio na predição da amostra de validação.



**Figura 1:** Estimativas do erro quadrático médio-EQM (A) e coeficiente de determinação- $R^2$  (B) obtidos, considerando diferentes números de neurônios na camada intermediária. Os desvios referem-se aos limites inferiores e superiores ao nível de 95% confiança obtida por bootstrap com 10.000 simulações.


Assim, foram testados modelos de RNA para prever a produtividade do mamoeiro CNPMF-L78 por meio dos caracteres vegetativos. Ao analisar o coeficiente de determinação ( $R^2$ ), resultados razoáveis foram averiguados com dois neurônios na camada intermediária, em que o ajuste dos dados possibilitou prever a produtividade em 55% (Figura 1B). Essa estrutura de rede foi selecionada com base no menor valor do EQM (AZEVEDO et al., 2019) associado ao  $R^2$ . Na Figura 2A é possível verificar a topologia da melhor adequação da rede com os caracteres vegetativos, ao passo que a Figura 2B mostra a contribuição relativa dos caracteres com maior importância para expressar a produtividade.



**FIGURA 2:** Topologia da melhor rede ajustada (A) e contribuição relativa – CR (B), obtida pelo método de Garson (1991), dos parâmetros agrônômicos, (AP- altura da planta, DC- diâmetro do caule, avaliada aos seis, 12 e 18 meses de idade; AIPF- altura de inserção da primeira flor funcional) apresentada na camada de entrada e diâmetro do caule avaliado aos seis, 12 e 18 meses para a predição da produtividade mamoeiro CNPMF-L78 por redes neurais artificiais. Os desvios referem-se aos intervalos de confiança de 95%, obtidos por bootstrap BCa com 10.000 simulações.

Pela importância relativa das características preditivas, ponderadas pelo método de Garson (1991), o diâmetro do caule avaliado aos 18 meses de idade (Figura 2B) foi o caractere mais relevante com contribuição relativa de 19% no rendimento do mamoeiro. Dentre os caracteres vegetativos, a altura da planta e diâmetro do caule avaliados aos 6 meses de idade apresentaram as menores contribuições relativas com 5,12% e 8,87%, nesta ordem, para estimativa da produtividade (Figura 2B).

Para testar a eficiência do modelo de predição, a produtividade estimada foi comparada com a produtividade observada por meio das variáveis de entrada destinadas à amostra de validação ajustadas por redes neurais com valores de  $R^2$  de 0,55 (Figura 3).



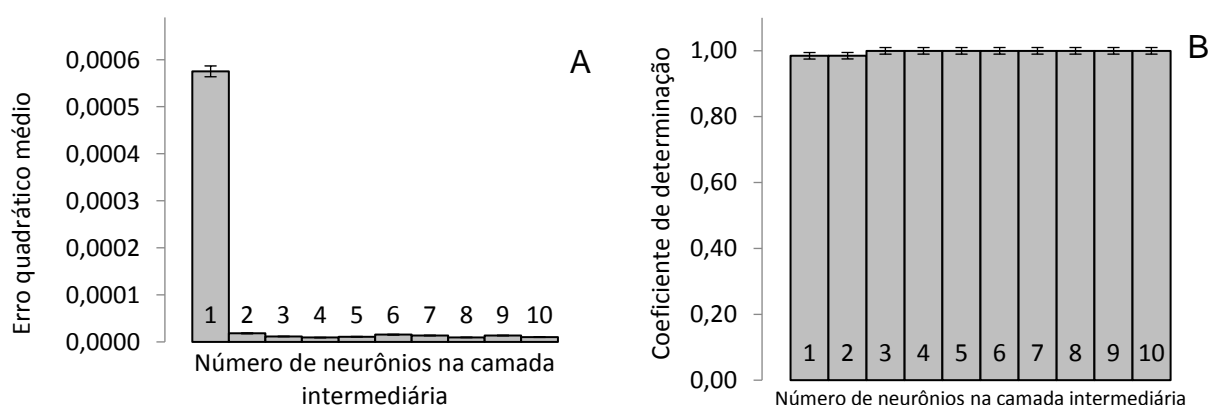
**Figura 3:** Representação gráfica da qualidade de predição da produtividade do mamoeiro CNPMF-L78 por redes neurais artificiais para a amostra de validação considerando todos os caracteres avaliados.

Uma boa consistência dos dados é muito importante para fins de predição de rendimentos em plantios comerciais, pois podem ser utilizados para alimentar modelos matemáticos de predição do rendimento, gerando informações úteis para aperfeiçoar diversas atividades agrícolas, como a colheita, pós colheita, embalagem e comercialização (AGGELOPOULOU et al., 2011).

A seleção dos modelos e a comprovação de sua eficiência para generalização da RNA ocorreu em resposta ao  $R^2$  e a não significância ( $p > 0,05$ ) do teste t para a hipótese nula da inclinação da reta ( $H_0: b = 1$ ). Tonando possível o melhor entendimento do processo modelado (AZEVEDO et al., 2019).

### 3. 2. Modelagem dos dados de RNA para as características reprodutivas

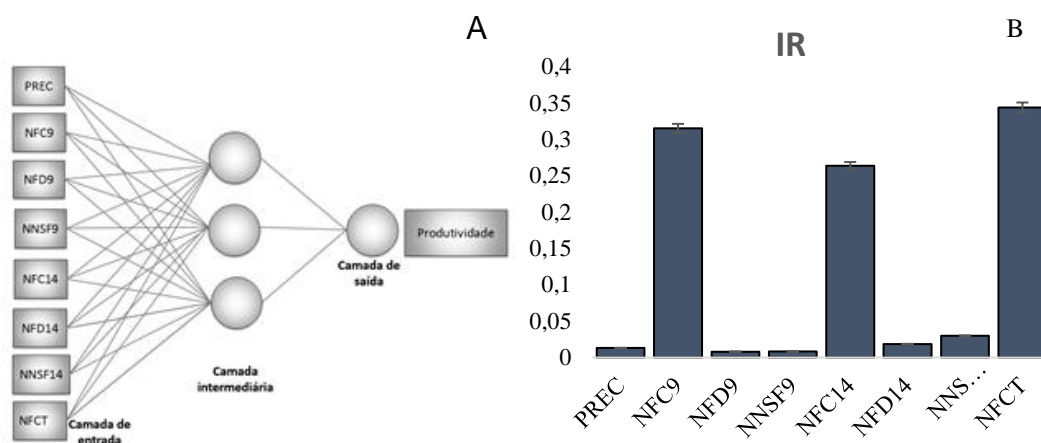
O desempenho das arquiteturas de rede para modelagem dos caracteres de produção do fruto: PREC (precocidade); NFC (número de frutos comerciais por planta); NFCT (número de frutos comerciais totais); NFD (número de frutos deformados por planta); NNSF (número de nós sem frutos) foi medido pelo erro quadrático médio (EQM) (Figura 4). Os números de neurônios das camadas intermediárias são expressos no EQM (Figura 4A) e amostra de treinamento e o coeficiente de determinação ( $R^2$ ) (Figura 4B).



**Figura 4:** Estimativas do erro quadrático médio-EQM (A) e coeficiente de determinação- $R^2$  (B) obtidos considerando diferentes números de neurônios na camada intermediária. Os desvios referem-se aos limites inferiores e superiores ao nível de 95% confiança obtidos por bootstrap com 10.000 simulações.

Resultados significativos foram obtidos quando se testou três neurônios na camada intermediária (Figura 4), em que o ajuste apresentou os menores erros do quadrado médio (EQM) (Figura 4A) associados aos maiores valores do coeficiente de determinação ( $R^2$ ) (Figura 4B).

Os menores valores de EQM representam a maior proximidade entre os dados previstos e reais e, portanto, a maior eficiência das redes na previsão do rendimento. O  $R^2$ , expressou resultados satisfatórios quando ponderados para o número de três neurônios na camada intermediária, com ajuste dos dados em 99,98% (Figura 4B). A estrutura da rede com três neurônios na camada intermediária é apresentada na Figura 5A, com a estratificação da contribuição relativa expressa pela Figura 5B.




**FIGURA 5:** Topologia da melhor rede ajustada (A) e contribuição relativa (B), obtida pelo método de Garson (1991), dos parâmetros agrônômicos (PREC-precocidade; NFC- número de frutos comerciais por planta (avaliado aos 9 e 14 meses); NFCT- número de frutos comerciais totais (soma); NFD- número de frutos deformados por planta e NNSF-número de nós sem frutos) apresentados na camada de entrada para a previsão da produtividade mamoeiro CNPMF-L78 por redes neurais artificiais. Os desvios referem-se aos intervalos de confiança de 95%, obtidos por bootstrap BCa com 10.000 simulações.

As características preditivas com maior importância no processo de previsão pelas RNA's foram ligadas ao número de frutos comerciais totais e o número de frutos comerciais aos nove meses de idade com 34,38 e 31,50% de contribuição relativa, respectivamente (Figuras 5B). Já os caracteres de menores contribuições preditivas foram o número de frutos deformados por planta e número de nós sem frutos, avaliados aos 9 meses, com as respectivas contribuições de 0,8 e 0,81% (Figura 5B).

Estudos dessa natureza têm importância por avaliar um maior número de características, principalmente quando se torna rendável a exclusão de características para a redução de mão-de-obra (PALIWAL; KUMAR, 2011).

Para testar a eficiência do modelo de predição, a produtividade estimada foi comparada com a produtividade observada por meio das variáveis de entrada destinadas à amostra de validação. Assim, o modelo de RNA obteve sucesso devido à similaridade entre os dados observados e previstos, testados com valores de  $R^2$  de alta significância 0,99 (Figura 6).



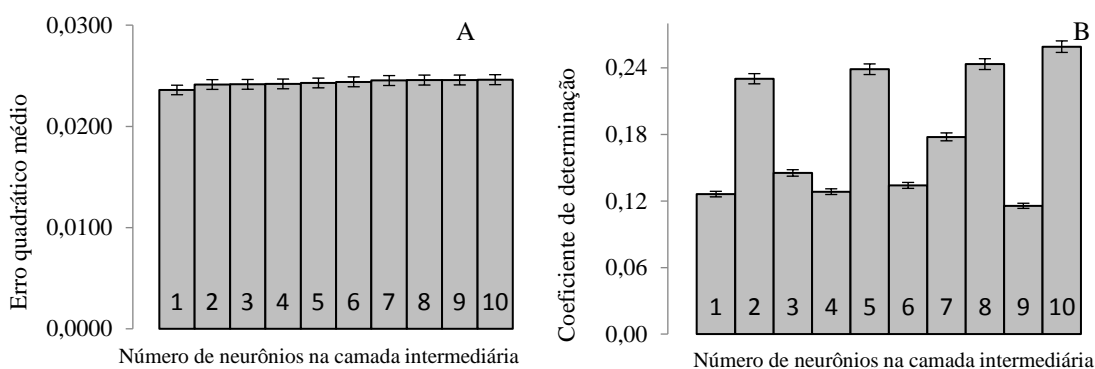
**Figura 6:** Representação gráfica da qualidade de predição da produtividade do mamoeiro CNPMF-L78 por redes neurais artificiais para a amostra de validação considerando todos os caracteres avaliados.

Ao selecionar modelo de predição, deve-se considerar a melhor relação entre o número de amostras de treinamento e o número de conexões intermediárias, sendo que este último deve ser superior a dois, pois favorece o menor erro relativo médio de validação (SOARES et al., 2015; GUIMARÃES et al., 2021). Similarmente por RNA, alcançou-se a estimativa da produção de frutos de pimenta com a arquitetura 8:10:1 precisão  $R^2 = 0,97$ , obtendo com o caracter número de frutos por planta maior determinação da produtividade dos frutos (GHOLIPOOR; NADALI, 2019).

Nestes modelos, foram consideradas características de fácil mensuração em campo, e que podem ser medidas no momento de inserção dos primeiros frutos comerciais, no caso deste estudo, cerca de nove meses após o plantio Donato et al. (2015), o que facilita o agendamento da colheita e a previsão de entrega pelo produtor (GUIMARÃES et al., 2021).

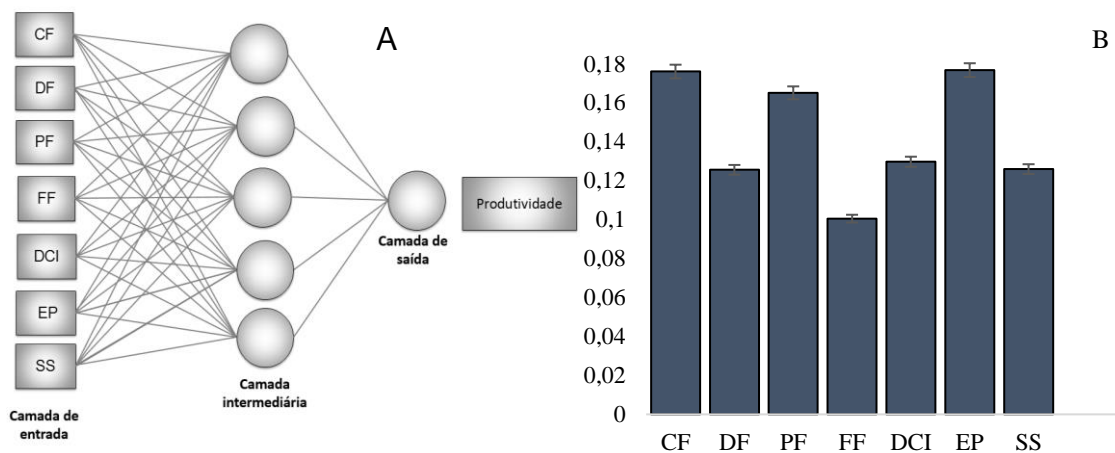
### 3. 3. Modelagem dos dados de RNA para as características de qualidade e rendimento do fruto

A modelagem de Redes Neurais Artificiais em mamoeiro CNPMF-L78, também foi empregada para medir os caracteres de qualidade e rendimento do fruto (CF) comprimento de fruto; (DF) diâmetro de fruto; (PF) peso de fruto; (FF) firmeza do fruto; (DCI) diâmetro da cavidade interna do fruto; (EP) espessura da polpa; (SS) sólidos solúveis. O funcionamento das arquiteturas de rede foi medido pelo erro quadrático médio (EQM) (Figuras 7A) e pelo coeficiente de determinação ( $R^2$ ) (Figuras 7B).




**Figura 7:** Estimativas do erro quadrático médio-EQM (A) e coeficiente de determinação-  $R^2$  (B) obtidos considerando diferentes números de neurônios na camada intermediária. Os desvios referem-se aos limites inferiores e superiores ao nível de 95% confiança obtidos por bootstrap com 10.000 simulações.

Para variáveis relacionadas à qualidade e rendimento do fruto, constatou-se que o ajuste da rede com cinco neurônios na camada intermediária apresentou os menores erros do quadrado médio (EQM) (Figura 7A) associados aos maiores valores do coeficiente de determinação ( $R^2$ ) (Figura 7B). Contudo, foram encontrados resultados insatisfatórios, mesmo para o melhor ajuste, com o número médio de cinco neurônios na camada intermediária, o que proporcionou apenas 23,87% da eficiência preditiva (Figura 7B). A estrutura de redes com cinco neurônios na camada intermediária é apresentada na Figura 8.



**FIGURA 8:** Topologia da melhor rede ajustada (A) e contribuição relativa (B), obtida pelo método de Garson (1991), dos parâmetros agrônômicos (CF- comprimento de fruto; DF- diâmetro de fruto; PF- peso de fruto; FF- firmeza do fruto; DCI- diâmetro da cavidade interna do fruto; EP- espessura da polpa e SS- sólidos solúveis) apresentados na camada de entrada para a predição da produtividade mamoeiro CNPMF-L78 por redes neurais artificiais. Os desvios referem-se aos intervalos de confiança de 95%, obtidos por bootstrap BCa com 10.000 simulações.

Quanto à importância relativa das variáveis respostas, verificou-se que a variável de qualidade do fruto espessura da polpa teve maior importância (Figura 8B), com contribuição relativa de 17,68%. A maior expressão do parâmetro EP corrobora o moderado coeficiente de correlação com a produtividade do mamoeiro. Já a característica firmeza do fruto teve a menor contribuição relativa (10%). Foram ajustadas redes neurais com  $R^2$  de 24% para a amostra de validação (Figura 9).



**Figura 9:** Representação gráfica da qualidade de predição da produtividade do mamoeiro CNPMF-L78 por redes neurais artificiais para a amostra de validação considerando todos os caracteres avaliados.

Mesmo com baixos valores de precisão ligados aos caracteres vegetativos e de qualidade de rendimento foi possível evidenciar medidas de importância relativa para cada variável. Destacando a utilidade das Redes Neurais Artificiais, como meio de avaliação a ser utilizada em identificação de variáveis com maior e menor contribuição, além disso tais variáveis podem proporcionar o reconhecimento de genótipos superiores, subsidiando estudos em melhoramento genético.

Estudos com alto desempenho da RNA na obtenção das variáveis de interesse agrônomo, têm sido difundidos em diversos ecossistemas (GEMICI et al., 2019; VITOR et al., 2019; NIEDBALA, 2019; HEIDARI; REZAEI; ROHANI, 2020; LIU et al., 2021). Dentre os motivos associados à eficiência dos modelos RNA, existe o menor erro preditivo, o que converte na maior eficiência preditiva do processo.

Ressalta-se no presente estudo que as variáveis associadas aos descritores de rendimento apresentaram maior poder de predição da produtividade do mamoeiro em detrimento das variáveis relacionadas às características vegetativas e reprodutivas do fruto. O que sinaliza para a construção do planejamento agrícola, a utilização de modelos com as características ligadas ao rendimento.

#### **4. CONCLUSÃO**

As previsões de produtividade do mamoeiro CNPMF-L78 foram obtidas com por meio de redes neurais artificiais do tipo Perceptron Multicamadas.

Os resultados deste estudo comprovam a aplicação dos modelos de RNA's, na previsibilidade da produtividade em mamoeiro CNPMF-L78, tornando-se uma ferramenta eficiente e estratégica na tomada de decisões da produção agrícola, sobretudo no que diz respeito ao planejamento de pós colheita, armazenamento e transporte.

Os caracteres morfoagronômicos com maior contribuição relativa na previsão do rendimento do mamoeiro CNPMF-L78 foram associados ao número de frutos comerciais avaliado aos nove e quatorze meses de idade e o número de frutos comerciais totais.



## REFERÊNCIA

AGGELOPOULOU, A. D.; BOCHTIS, D.; FOUNTAS, S.; SWAIN, K. C.; GEMTOS, T. A.; NANOS, G. D. Yield prediction in apple orchards based on image processing. **Precision Agriculture**, v.12, ed.3, p.448-56, 2011.

AZEVEDO, A. M. de; SILVEIRA, V. A. da; OLIVEIRA, C. M.; PEDROSA, C. E.; LEMOS, V. T.; VALADARES, N. R.; Guimarães, A. G. Predição da área foliar em acerola por redes neurais e regressão múltipla. **Revista Agrária Acadêmica**, v.2, n.3, 2019.

BERGMEIR, C.; BENÍTEZ, J. M. Redes neurais em R usando o Simulador de Redes Neurais de Stuttgart: RSNNS. **Journal of Statistical Software**, v. 46, n. 1, p. 1-26, 2012.

DONATO, S. L. R.; COELHO, E. F.; MARQUES, P. R. R.; ARANTES, A. de M. Considerações ecológicas, fisiológicas e de manejo. IN: **FERREIRA, CF; SILVA, S. de O. e; AMORIM, EP; SANTOS-SEREJO, JA dos.** O agronegócio da banana. Brasília, DF: Embrapa, p.45-110, 2015.

Embrapa. **VII Plano Diretor da Embrapa: 2020–2030 / Embrapa.** – Brasília, DF: Embrapa, 1ª ed., p.31, 2020.

GARSON, G. D. Interpretando pesos de conexão de redes neurais. **International Journal of Artificial Intelligence and Expert Systems**, v.6, n.1, p.47-51, 1991.

GEMICI, E.; YUCEDAG, C.; OZEL, H. B.; IMREN, E. Predição da produção de cones em pomar de sementes clonais de pinheiro negro da Anatólia com rede neural artificial. **Ecologia Aplicada e Pesquisa Ambiental**, v.17, n.2, pág. 2267-2273, 2019.

GHOLIPOOR, M.; NADALI, F. Previsão de produção de frutas de pimenta usando rede neural artificial. **Scientia Horticulturae**, v.250, p.249-253, 2019.

GUIMARÃES, B. V. C.; DONATO, S. L. R.; ASPIAZÚ I.; AZEVEDO, A. M. Previsão de rendimento de 'Prata Anã' e Bananeiras 'BRS Platina' por redes neurais artificiais. **Pesquisa Agropecuária Tropical**, Goiânia, v.51, e66008, 2021.

GUIMARÃES, B. V. C.; DONATO, S. L. R.; AZEVEDO, S. O. U.; ASPIAZÚ, I.; SILVAJUNIOR, A. A. e. Predição da produção de palma forrageira "Gigante" por caracteres morfológicos e redes neurais artificiais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.22, n.5, pág.315-319, 2018.

HEIDARI, P.; REZAEI, M.; ROHANI, A. Abordagem baseada em computação soft na previsão promissora de mudas de pistache com base nas características da folha. **Scientia Horticulturae**, v.274, art.109647, 2020.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Cidades e estados.** 2909802. Cruz das Almas- BA, 2020. Disponível em: <https://cidades.ibge.gov.br/brasil/ba/cruz-das-almas/coordenadas>. Acessado em: 22.07.2021.

IUSS Working Group WRB. World reference base for soil resources 2014, update 2015. **International soil classification system for naming soils and creating legends for soil maps. Rome: FAO; 2015.** (World Soil Resources Reports, 106).

LIU, L-W.; MA, X.; WANG, Y-M.; LU, C-T.; LIN, W-S. Usando algoritmos de inteligência artificial para prever arroz (*Oryza sativa* L.) taxa de crescimento para agricultura de precisão. **Computers and Electronics in Agriculture**, v.187, art.106286, 2021.

MAMANN, A. T.; SILVA, J. A. G.; BINELO, M. O.; SCREMIN, O. B.; KRAISIG, A. R.; CARVALHO, I.R.; PEREIRA, L. M.; BERLEZI, J. D.; BERLEZI, J. D.; ARGENTA, C. V. Artificial intelligence simulating grain productivity during the wheat development considering biological and environmental indicators. **Journal of agricultural studies**, v.7, p.197-212, 2019.

MERLADETE, A. Digitalização da cadeia agrícola já é realidade Brasil afora. **Agrolink**, 2021. Disponível em: [https://www.agrolink.com.br/noticias/digitalizacao-da-cadeia-agricola-ja-e-realidade-brasil-afora\\_454406.html](https://www.agrolink.com.br/noticias/digitalizacao-da-cadeia-agricola-ja-e-realidade-brasil-afora_454406.html). Acessado em 25.08.2021.

MISHRA, R.; VARUN, P.; HANS, A. L.; SAXENA, S.; Capítulo 21 - Análise da diversidade de begomovírus que infectam o mamão e seus mecanismos de resistência. In: **Plant Virus-Host Interaction- 2ª ed.** Academic Press, p.507-524, 2021.

NIEDBALA, G. Modelo simples baseado em rede neural artificial para previsão antecipada e simulação de safra de colza de inverno. **Journal of Integrative Agriculture**, v.18, ed.1, p.54-61, 2019.

OLIVEIRA, A. M. G; Souza, L. D; Coelho, E. F. Recomendações de calagem e adubação para mamoeiro. Embrapa Mandioca e Fruticultura. Comunicado técnico 139, ISSN- 1809- 502X. 2010.

PALIWAL, M.; KUMAR, U. A. Assessing the contribution of variables in feed forward neural network. **Applied Soft Computing**, v.11, n. 4, p.3690-3696, 2011.

PAN, J.; PANT, R. P.; SINGH, M. K.; SINGH, D. P.; PANT, H. Analysis of agricultural crop yield prediction using statistical techniques of machine learning. **Materials Today: Proceedings** ISSN: 22147853. Anais [Internet]. Elsevier BV, 2021. Disponível em: <http://dx.doi.org/10.1016/j.matpr.2021.01.948>. Acessado em: 19.07.2021.

R CORE TEAM. *R: uma linguagem e ambiente para computação estatística.* Viena: RFoundation for Statistical Computing, 2018.

SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A., LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A.; ARAÚJO FILHO, J. C., OLIVEIRA J. B; CUNHA T. J. F. Sistema brasileiro de classificação de solos. **Rev. and Exp**, 5. ed., p.356 Brasília, DF: Embrapa; 2018.

SANTOS, J. F. S. Produção de soja, desigualdades no campo e mudanças climáticas na região do Matopiba. **Desenvolvimento Regional em Debate**, v. 10, p.535-561, 2020.

SOARES, F. C.; ROBAINA, A. D.; PEITER, M. X.; RUSSI, J. L. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, v.45, n.11, p.1987-1993, 2015.

SOARES, J. D. R.; PASQUAL, M.; LACERDA, W. S.; SILVA, S. O.; DONATO, S. L. R. Comparação de técnicas utilizadas na predição da produtividade em bananeira. **Scientia Horticulturae**, v.167, n.1, p.84-90, 2014.

SOIL SURVEY STAFF. Keys to soil taxonomy. **Department of Agriculture, Natural Resources Conservation Service**, ed.12, p. 372. Washington, DC: United States, 2014.

VITOR, A. B.; DINIZ, R. P.; MORGANTE, C. V.; ANTÔNIO, R. P.; OLIVEIRA E. J. de. Modelos de previsão inicial para a produção de raízes de mandioca em diferentes regimes de água. **Pesquisa de colheitas de campo**, v. 239, p.149-158, 2019.

## **CONSIDERAÇÕES FINAIS**

O intuito da proposta deste estudo foi fornecer subsídios suficientes para garantir o maior nível de eficiência para obtenção da produtividade do mamoeiro Linhagem CNPMF-L78.

O desenvolvimento de modelos de predição utilizando mensurações não destrutivas e de fácil aplicação no campo por meio da Análise de Correlação, Regressão Linear Simples e Múltipla e Redes Neurais Artificiais, demonstraram serem eficientes para estimar a produtividade em mamoeiro Linhagem CNPMF-L78.

Ainda é possível ponderar, que além das estimativas, os modelos também expuseram características de forte propensão ao rendimento, podendo estas serem alvos de estudos futuros no melhoramento genético.

A compreensão deste trabalho servirá como subsídio e suporte para se obter resultados eficientes para a estimativa da produtividade em mamoeiro Linhagem CNPMF-L78, tornando-se uma ferramenta eficiente e estratégica na tomada de decisões da produção agrícola, sobretudo, no que diz respeito ao planejamento de pós colheita, armazenamento e transporte.