

UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL

**ASSOCIAÇÃO ENTRE EL NIÑO-OSCILAÇÃO SUL E A
VARIAÇÃO GEOGRÁFICA DA PRODUTIVIDADE DO CAFÉ**

Karita Almeida Silva

Engenheira Agrônoma

2020

UNIVERSIDADE ESTADUAL PAULISTA - UNESP
CÂMPUS DE JABOTICABAL

**ASSOCIAÇÃO ENTRE EL NIÑO-OSCILAÇÃO SUL E A
VARIAÇÃO GEOGRÁFICA DA PRODUTIVIDADE DO CAFÉ**

Karita Almeida Silva

Orientador: Prof. Dr. Glauco de Souza Rolim

Coorientador: Prof. Dr. Alan Rodrigo Panosso

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

2020

S586a Silva, Karita Almeida
Associação entre El Niño-Oscilação Sul e a variação geográfica da
produtividade do café / Karita Almeida Silva. -- Jaboticabal, 2020
73 f. : il., tabs., mapas

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp),
Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal
Orientador: Glauco de Souza Rolim
Coorientador: Alan Rodrigo Panosso

1. ENSO. 2. Inteligência artificial. 3. Mudanças climáticas. I. Título.

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

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: ASSOCIAÇÃO ENTRE EL NIÑO-OSCILAÇÃO SUL E A VARIAÇÃO GEOGRÁFICA DA PRODUTIVIDADE DO CAFÉ

AUTORA: KARITA ALMEIDA SILVA


ORIENTADOR: GLAUCO DE SOUZA ROLIM

COORDINADOR: ALAN RODRIGO PANOSSO

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


Prof. Dr. ALAN RODRIGO PANOSSO
Departamento de Ciências Exatas / FCAV-UNESP/Jaboticabal-SP


Profa. Dra. AMANDA LIZ PACÍFICO MANFRIM PERTICARRARI
Departamento de Ciências Exatas / FCAV / UNESP - Jaboticabal


Prof. Dr. MÁRCIO JOSÉ DE SANTANA
Departamento de Agronomia / IFTM - Uberaba/MG

Jaboticabal, 17 de fevereiro de 2020

DADOS CURRICULARES DA AUTORA

KARITA ALMEIDA SILVA – nascida em Prata, Minas Gerais, no dia 27 de julho de 1994, filha de Antônia Elizabeth Almeida Silva e Antônio da Silva Lima. Ingressou no curso de Engenharia Agrônômica no Instituto Federal de Educação, Ciência e Tecnologia do Triângulo Mineiro (IFTM), Câmpus Uberaba, em fevereiro de 2013. No mesmo Câmpus, foi bolsista do Programa de Educação Tutorial (PET) durante a gestão 2013-2017, no qual desenvolveu as áreas de pesquisa, ensino, extensão e gestão de pessoas. Realizou seu estágio obrigatório na área de P&D na Usina Bunge Brasil, entre agosto de 2017 e janeiro de 2018. Em fevereiro de 2018 obteve o título de Engenheira Agrônoma. Em março de 2018 ingressou no programa de mestrado em Agronomia (Produção Vegetal) na Faculdade de Ciências Agrárias e Veterinárias, UNESP, Câmpus Jaboticabal, onde aproximadamente dois anos depois, defende sua dissertação para obtenção do título de mestre em Agronomia (Produção Vegetal). Ao longo de sua trajetória acadêmica seguiu as linhas de pesquisa em agrometeorologia e modelagem de cultivos agrícolas.

Aos meus pais, Antônia Elizabeth e Antônio, e à minha irmã Carolinne que me proporcionaram o maior amor do mundo e abdicaram de muitas coisas ao longo deste caminho para que eu realizasse meu sonho.

A vocês, **DEDICO!**

Aos meus padrinhos e madrinhas, **OFEREÇO!**

AGRADECIMENTOS

Acima de tudo agradeço a Deus, o qual sempre esteve à frente da minha caminhada. Me dando serenidade para aceitar as coisas que não podia modificar, coragem para modificar as que eu podia, e sabedoria para reconhecer a diferença entre ambas.

À Universidade Estadual Paulista “Júlio de Mesquita Filho”, Faculdade de Ciências Agrárias e Veterinárias, Campus de Jaboticabal, em especial ao Programa de Pós-Graduação em Agronomia (Produção Vegetal).

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

Ao meu orientador Prof. Dr. Glauco de Souza Rolim, por me ensinar o verdadeiro sentido da pesquisa científica, pelo exemplo de dedicação ao trabalho, bem como pela paciência com todos nós, seus orientandos. Muito obrigada por toda dedicação e ensinamentos, tenho uma admiração e consideração imensa pelo seu trabalho.

Ao meu coorientador Prof. Dr. Alan Rodrigues Panosso pela confiança, apoio e colaboração para realização deste trabalho.

Aos membros da banca da defesa, Profa. Dra. Amanda Liz Pacífico Manfrim Perticarrari e Prof. Dr. Márcio José de Santana, os quais muito contribuíram para a Dissertação.

À toda minha família em especial minha mãe, Antônia Elizabeth; meu pai, Antônio; minha irmã Carolinne; meus padrinhos José Antônio e Roberto; minhas madrinhas Maria Elisabete e Fabiana; e minha afilhada Izabella, que sempre dedicaram tempo e conselhos a mim, nunca questionaram minhas decisões, mas sim apoiaram minhas escolhas durante todos esses anos de estudos até aqui. Obrigado por vocês acreditarem em mim!

À minha prima Maria Eduarda, minha segunda irmã, agradeço pela cumplicidade, lealdade, carinho e amizade de todos esses anos.

Às minhas amigas de infância, Bruna Sousa e Laila Góes que, apesar da distância, sempre estiveram presentes em minha vida.

Às minhas irmãs de coração, Amanda Yamada, Rayeny Ávila e Taynara Valeriano que em meus momentos mais felizes estiveram ao meu lado e nos momentos mais tristes não hesitaram em me ajudar. Obrigada por sempre estarem ao meu lado, apesar da distância, e fazerem a minha vida mais feliz!

Aos amigos que ganhei durante estes dois anos em Jaboticabal, Adão, Edgard, Everton e Letícia, que fizeram meus dias mais felizes e preencheram todos os meus almoços de domingo amenizando a saudade de casa.

Às minhas amigas Kamila, Larissa, Maria Albertina e Stefany, que me deram apoio incondicional durante o mestrado e me presentearam com uma linda amizade.

Aos meus amigos e parceiros do GAS e do departamento de Ciências Exatas, José Reinaldo, Victor Moreto, Lucas Aparecido, Paulo, Aline, Valter, Mary Jane, Lígia, Nayane, Tatiana, Washington, Gustavo, Fernando, Bruna, Kleve, Ludhanna, Gabriela e Thiago. Obrigada pela convivência e troca de experiência durante esse tempo, vocês fizeram do departamento de exatas o melhor da UNESP.

Aos colegas do Departamento de Ciências Exatas, Prof. Newton, Prof. Peruzzi, Zezé, Shirlei, Adriana e Carlão, muito obrigada pela convivência durante esse tempo.

A todos que de alguma forma contribuíram para que chegasse até aqui, o meu muito obrigada!

SUMÁRIO

	Página
RESUMO	ii
ABSTRACT	iii
LISTA DE ABREVIATURAS	iv
CAPÍTULO 1 – Considerações gerais.....	1
1.1 Introdução.....	1
1.2 Revisão de Literatura.....	2
1.2.1 A importância do café para o agronegócio brasileiro.....	2
1.2.2 Influências do clima no desenvolvimento e produtividade do café	4
1.2.3 El Niño-Oscilação Sul (ENSO)	5
1.2.4 Uso de inteligência artificial como modelo de previsão	7
1.2.5 Árvores de decisão para classificação	8
1.3 Referências.....	9
CAPÍTULO 2 - Previsão de eventos de El Niño e La Niña por inteligência	
artificial	17
2.1 Introdução.....	18
2.2 Material e métodos	20
2.3 Resultados e discussão	26
2.4 Conclusão.....	33
2.5 Referências.....	34
CAPÍTULO 3 - Influence of El Niño and La Niña on coffee yield in the main	
coffee-producing regions of Brazil.....	38
3.1 Introduction	38
3.2 Data and methodology	40
3.3 Results and discussion	43
3.4 Conclusion	54
3.5 References	56
CAPÍTULO 4 – Considerações finais.....	61

Associação entre El Niño-Oscilação Sul e a variação geográfica da produtividade do café

RESUMO - O fenômeno El Niño-Oscilação Sul é um fator chave na variabilidade climática, sendo formado pelos episódios de El Niño e La Niña e classificado como um fenômeno de grande escala no Oceano Pacífico Tropical. Em razão do grande efeito deste fenômeno nos elementos meteorológicos, principalmente nos padrões de temperatura e precipitação, faz-se necessário estudos sobre a antecipação de sua previsão e da sua influência na produtividade de culturas agrícolas, como o café. O café é uma cultura que representa grande importância socioeconômica para o Brasil, sendo cultivada em mais de 2 milhões de hectares e, além de ser uma das commodities mais valiosas mundialmente, é muito sensível à mudança das condições climáticas. Diante disso, o objetivo deste trabalho é prever episódios quentes e frios do ENSO, de forma a obter um modelo simples e acurado, que auxilie na gestão agrícola da cultura do café. Para tanto, este trabalho apresenta informações importantes sobre o fenômeno El Niño-Oscilação Sul e sua influência no cafeeiro, como (i) Previsão de eventos de El Niño e La Niña por inteligência artificial e (ii) Influência do El Niño e La Niña na produtividade do café, nas principais regiões produtoras de café do Brasil. Os resultados encontrados neste trabalho foram eficientes e promissores para aplicação prática. O modelo de previsão apresentou boa acurácia em condições de anos de El Niño, La Niña e neutros, com média de 84% e conseguiu prevê-los com 9 meses de antecedência. A utilização de árvores de decisão para classificação com o objetivo de prever episódios quentes e frios do fenômeno El Niño-Oscilação Sul se mostrou uma alternativa promissora e de fácil acesso em relação a outras técnicas de inteligência artificial. Observou-se ainda correlação significativa entre os fenômenos do El Niño-Oscilação Sul com a temperatura do ar, precipitação, evapotranspiração potencial, armazenamento de água no solo, deficiência hídrica e excedente hídrico, influenciando, portanto, na produtividade do café em todas as regiões estudadas.

Palavras-Chave: ENSO, inteligência artificial, mudanças climáticas

Association between El Niño-South Oscillation and the geographical variation of coffee yield

ABSTRACT - The El Niño-Southern Oscillation phenomenon is a key factor in climate variability, being formed by the El Niño and La Niña episodes and classified as a large-scale phenomenon in the Tropical Pacific Ocean. Due to the great effect of this phenomenon on the meteorological elements, especially on the temperature and precipitation patterns, studies on the anticipation of its prediction and its influence on the productivity of agricultural crops, such as coffee. Coffee is a crop that is of great socioeconomic importance for Brazil, being grown on over 2 million hectares and, besides being one of the most valuable commodities in the world, it is very sensitive to changing weather conditions. Therefore, this work presents important information about the El Niño-Southern Oscillation phenomenon and its influence on coffee, as (i) Forecasting El Niño and La Niña events using artificial intelligence and (ii) Influence of El Niño and La Niña on coffee yield in the main coffee-producing regions of Brazil. The results found in this work were efficient and promising for practical application. The model showed good accuracy in forecasting El Niño, La Niña and neutral year conditions, averaging 84% and was able to predict them 9 months in advance. The use of decision trees classifier to predict hot and cold episodes of the El Niño-Southern Oscillation phenomenon has shown to be a promising and easily accessible alternative to other artificial intelligence techniques. There was also a strong correlation between El Niño-Southern Oscillation phenomenon with air temperature, precipitation, potential evapotranspiration, soil water storage, water deficit and water surplus, thus influencing coffee yield in all production regions studied.

Palavras-Chave: ENSO, artificial intelligence, climate changes

LISTA DE ABREVIATURAS

DTC – Árvore de decisão para classificação

EN – El Niño

ENSO – El Niño-Oscilação Sul

FN – Falso negativo

FP – Falso positivo

IA – Inteligência Artificial

LN – La Niña

MAAO – Modelos acoplados atmosfera-oceano

ML – Aprendizagem de máquina

NE – Neutro

NOAA – National Oceanic and Atmospheric Administration

ONI – Índice Oceânico Niño

SOI – Índice de Oscilação Sul

SST – Temperatura da superfície do mar

VN – Verdadeiro negativo

VP – Verdadeiro positivo

VPN – Valor preditivo negativo

VPP – Valor preditivo positivo

CAPÍTULO 1 – Considerações gerais

1.1 Introdução

O El Niño-Oscilação Sul (ENSO) refere-se à alternância entre duas fases climáticas distintas, a fase de El Niño e sua fase oposta, La Niña. O ENSO é acompanhado por um deslocamento da circulação atmosférica refletido pelo Índice de Oscilação do Sul (Southern Oscillation Index, SOI) e por mudanças na temperatura da superfície do mar (Sea Surface Temperature, SST) cujos aspectos se acredita serem previsíveis (Latif et al., 1998).

O ENSO influencia a agricultura global de várias maneiras, inclusive através de mudanças nos parâmetros hidrometeorológicos (Casanueva et al., 2014; Sun et al., 2015; Veldkamp et al., 2015; Ward et al., 2010) e climáticos (Barlow et al., 2001; Dilley e Heyman, 1995; Donat et al., 2014), que afetam direta ou indiretamente a produtividade, a produção e os preços de diversas culturas (Iizumi et al., 2014; Ray et al., 2015; Rowhani et al., 2011).

O uso de informações climáticas com prazos longos, como as previsões sazonais do El Niño-Oscilação Sul, permitem que os agricultores antecipem riscos e melhorem sua gestão em várias partes do mundo (Bussay et al., 2015; Haigh et al., 2015; Iizumi et al., 2014; Meinke e Stone, 2005; Motha e Baier, 2005; Nnaji, 2001), inclusive para culturas como soja, milho, trigo e cevada (Nóia Júnior e Sentelhas, 2019; Cunha et al., 2001a,b).

Muitos estudos indicam que o padrão de precipitação na América do Sul, em particular em algumas regiões do Brasil, é fortemente afetado pelos extremos da Oscilação Sul (Ropelewski e Halpert, 1987; Rao e Hada, 1990; Gurgel e Ferreira, 2003). Na floresta tropical do norte da Amazônia e no nordeste do Brasil, baixas quantidades de precipitação foram observadas durante os anos de El Niño (Aceituno, 1988; Marengo, 1992; Uvo, 1998; Williamson et al., 2000).

De forma geral, os impactos provocados por estes fenômenos vão desde alterações na circulação regional quanto na global, resultando em anomalias climáticas, afetando diretamente padrões de vento e da temperatura do ar e

modificando o regime da precipitação pluvial em diferentes regiões do Brasil (Berlato e Fontana, 2003).

As condições climáticas tem alta correlação com a produtividade das culturas, causando grande impacto nas atividades agrícolas (Sá Júnior et al., 2012). Hoogenboom (2000) salienta que os elementos meteorológicos críticos na produção agrícola são a temperatura do ar, a radiação solar e a precipitação. Especificamente para o cafeeiro, a distribuição pluviométrica é um dos elementos que proporcionam maior interferência na fenologia do cafeeiro (Camargo, 2010).

Apesar da importância da previsão do fenômeno El Niño Oscilação-Sul para a gestão das atividades agrícolas, a previsão convencional ainda é limitada a 6 meses à frente (Ludescher et al., 2014) e, além disso, são escassos trabalhos que associam o fenômeno à cultura do café no Brasil. Por isso, o objetivo deste trabalho é prever episódios quentes e frios do ENSO, de forma a obter um modelo simples e acurado, que auxilie na gestão agrícola da cultura do café.

1.2 Revisão de Literatura

1.2.1 A importância do café para o agronegócio brasileiro

O café é uma planta perene pertencente à família *Rubiaceae* e ao gênero *Coffea* e inclui várias espécies. Pelo menos 25 espécies são originárias da África e de ilhas do Oceano Índico, incluindo as espécies *Coffea arabica* e *Coffea canephora*, mais conhecidas como café arábica e robusta, respectivamente. O *Coffea arabica* L. é uma das espécies com maior interesse econômico atualmente, devido ao seu cultivo em larga escala comercial, constituindo 70% da produção mundial de café (Fraser et al., 2014).

A produção global de café na safra 2017/2018 foi cerca de 170 milhões de sacas (60 kg). Os países em desenvolvimento são os principais produtores, liderados pelo Brasil, com 51 mi de sacas na safra de 2016, seguidos pelo Vietnã, com 30 mi de sacas, Colômbia, com 14 mi de sacas e Indonésia, com 12 mi de sacas. Além disso, o Brasil ocupa a posição de terceiro maior consumidor, atrás apenas da União Europeia e Estados Unidos (International Coffe Organization, 2020).

Por esse motivo, o café uma das culturas mais tradicionais da agricultura brasileira e, os principais estados brasileiros produtores de café arábica são Minas Gerais, São Paulo, Bahia e Paraná, enquanto Espírito Santo, Rondônia e Bahia são os principais estados produtores de café canéfora (Conab, 2020). O estado de Minas Gerais é responsável por 17% da produção de café mundial (Aparecido et al., 2017). O café cultivado em Minas Gerais acima de 900 m tem um ciclo de produção mais lento que promove boa formação de grãos, alta qualidade e produtividade (Bardin-Camparotto et al., 2012). Esta produção está concentrada principalmente no sul do estado mas, nos últimos anos, também vem se destacando o Cerrado Mineiro, com a cafeicultura irrigada (Ortega e Jesus, 2011).

A cafeicultura instalou-se no cerrado mineiro nos anos 70, tornando-o um dos mais importantes polos cafeeiros. De acordo com Andrade (1994), esse movimento ocorreu em razão da necessidade de expansão da fronteira agrícola no Estado de Minas Gerais. Mas, a princípio, o Instituto Brasileiro do Café (IBC) não considerava o local adequado à cultura, embora já houvesse vários estudos que viabilizavam sua implantação. O café produzido no cerrado é de alta qualidade, resultado de um bom estabelecimento das mudas e das condições climáticas favoráveis, propiciando estações bem definidas e produzindo grãos de altíssima qualidade (Simão, 1999).

As plantas de café têm como característica um ciclo fenológico bienal e dividido em seis fases, com alternância de produção semestral. Conforme descrito por Camargo e Camargo (2001), na primeira fase da cultura, as plantas de café tem início ao crescimento vegetativo e a formação de brotos vegetativos em setembro do primeiro ano até março do segundo ano no Brasil. A segunda fase, de abril a agosto do ano 2, também é vegetativa e se caracteriza pela diferenciação dos brotos vegetativos dos nós em brotos reprodutivos. A terceira fase é a expansão do florescimento e do grão, de setembro a dezembro do ano 2. A quarta fase é a formação e enchimento de grãos, de janeiro a março do ano 3 e, posteriormente, na quinta fase inicia-se a maturação dos grãos e a colheita, de maio a julho. A sexta fase é a senescência, que dura de julho a agosto do terceiro ano. Mas devido à extensão territorial do Brasil, o país apresenta grande variedade de microclimas, o que nem sempre é favorável para todas as fases da cultura.

1.2.2 Influências do clima no desenvolvimento e produtividade do café

As condições meteorológicas afetam fortemente os estádios fenológicos do cafeeiro (Picini et al., 1999) e, por isso, sua produção limita-se à zona intertropical de 20-25°N no Havaí e até 24°S no Brasil (Smith, 1989). As maiores limitações climáticas do café são a geada e o déficit hídrico. Pelo fato dos episódios de déficit hídrico serem mais frequentes do que as geadas, ele é considerado o principal estresse ambiental que afeta a produção da cultura (Damatta e Ramalho, 2006). Os déficits hídricos afetam a quantidade de umidade extraída pelas raízes, a distribuição espacial do sistema radicular, o tamanho do dossel e o crescimento de frutos das plantas de café (Amarasinghe et al., 2015). Além disso, o estresse hídrico após a fertilização afeta o crescimento dos frutos (Camargo, 2010)

A radiação solar provê a energia da fotossíntese (Oliveira et al., 2012), sendo uma variável meteorológica de importância, uma vez que origina o processo de transpiração e fotossíntese dos cultivos (Angelocci et al., 2008). A temperatura do ar regula a taxa de desenvolvimento vegetativo e reprodutivo, porém, temperaturas do ar elevadas, associadas ao déficit hídrico durante a florada, causam abortamento das flores (Pereira et al., 2008), sendo que a exposição contínua a temperaturas acima de 30°C resulta no amarelecimento das folhas e até à redução do crescimento (Damatta e Ramalho, 2006).

De acordo com Camargo e Camargo (2001), a faixa de temperatura ideal para o cultivo do café arábica situa-se entre 19 e 22 °C. Temperaturas mais altas promovem formação de botões florais e estimulam o crescimento dos frutos. Entretanto, estimulam também, a proliferação de pragas e aumenta o risco de infecções que podem comprometer a qualidade da bebida. O cafeeiro é pouco tolerante ao frio e também muito suscetível à geada, sendo que temperaturas do ar abaixo de 10 °C inibem o crescimento da planta e temperaturas próximas a -2 °C nas folhas, provoca início de danos aos tecidos.

Em regiões onde ocorrem temperaturas médias anuais superiores a 23 °C associadas à seca na época do florescimento provocam abortamento floral e formação de “estrelinhas”, o que implica na quebra de produção, principalmente nos anos em que a estação seca mostra-se mais longa ou atrasada (Camargo, 1985; Thomaziello

et al., 2000). Em regiões com médias anuais de 23 °C esse problema é mais grave, tudo indicando ser essa temperatura, limite de cultivo econômico do Café arábica a pleno sol (Camargo, 1985).

Já o cultivo do café robusta é realizado em diferentes condições de fertilidade dos solos e de altitude, com temperaturas médias anuais elevadas, precipitação de 1800 a 2200 mm ano⁻¹ com acentuado déficit hídrico de junho a setembro. Portanto, é uma opção agrícola interessante para as regiões de temperaturas médias anuais mais elevadas, cujas altitudes sejam inferiores a 600 m e não apresentem restrições de inverno frio, pois as regiões onde estão localizados os plantios dessa variedade possuem características de cultura pouco mecanizada. A espécie *C. canephora*, em geral, apresenta maior tolerância à seca e menor exigência em fertilidade por possuir um sistema radicular mais volumoso e, assim, atingir maiores profundidades, mesmo em solos de maior densidade. Entretanto, quando se trata de lavouras altamente tecnificadas com potencial produtivo acima de 100 sacas por hectare, as exigências hídricas e nutricionais passam a ser elevadas (Marcolan et al., 2009; Martins et al., 2006; Veneziano; Fazuoli, 2000).

1.2.3 El Niño-Oscilação Sul (ENSO)

O El Niño-Oscilação Sul é um fenômeno atmosférico caracterizado por anomalias da temperatura das águas do Oceano Pacífico Tropical que muda os padrões de vento e afetando os regimes de chuvas em regiões Tropicais e de Latitudes médias globalmente (Souza Júnior et al., 2009). Segundo Berlatto et al. (2005) o ENSO é composto por duas fases distintas a El Niño ou fase quente e a La Niña ou fase fria. O período do ciclo em que nem o El Niño nem o La Niña está presente é chamado de fase Neutra.

O Índice de Oscilação do Sul (SOI) é projetado para medir a força e a fase da Oscilação Sul. O SOI é calculado usando partidas de normal na diferença de pressão de ar de superfície entre Taiti, Polinésia Francesa e Darwin, Austrália. Essas estações são usadas por causa de seus longos registros de dados. Durante os episódios de El Niño, o SOI tem um grande valor negativo devido à pressão do ar abaixo da média no Taiti e à pressão acima da média em Darwin. Durante os episódios de La Niña, o SOI

tem um valor positivo devido à pressão do ar acima da média no Taiti e à pressão abaixo da média em Darwin. Os episódios de El Niño e La Niña ocorrem tipicamente a cada 3-5 anos. No entanto, no registro histórico, esse intervalo variou de 2 a 7 anos (Climate Prediction Center, 2018). Olantínwo et al. (2010), determinam um ano como El Niño ou La Niña quando o sinal ENSO é atingido para cada uma dessas fases por um mínimo de 5 trimestres consecutivos de sobreposição de médias de três meses.

A fase El Niño é causada por um aquecimento anormal das águas do oceano Pacífico que geralmente resulta em um aumento na precipitação nos anos em que ele ocorre. Já a fase La Niña é resultante de um resfriamento nas águas do oceano Pacífico gerando um efeito contrário ao El Niño, ou seja, uma redução na precipitação média dos anos em questão (Grimm et al., 2000). As duas fases deste fenômeno afetam o desempenho produtivo das espécies agrícolas de forma positiva e negativa e ainda, segundo Alves et al. (1997), o ENSO exerce grande influência sobre clima no mundo.

Diversos estudos verificaram que o ENSO tem fortes correlações com as anomalias de temperatura e precipitação e a frequência de eventos climáticos extremos nos Estados Unidos (Gershunov, 1998; Kiladis e Diaz, 1989; Ropelewski e Halpert, 1986; Wolter et al., 1999). Outros mostraram que os anos de El Niño na planície costeira do sudeste dos EUA tendem a ser mais frios e úmidos e os anos de La Niña tendem a ser mais quentes e secos entre outubro e abril (Kiladis e Diaz, 1989; Sittel, 1994a,b). O sinal ENSO é mais forte durante os meses de outono e inverno no sudeste dos EUA. No entanto, existem algumas evidências de que os verões do La Niña tendem a ser um pouco mais úmidos do que o normal.

Eventos de El Niño foram associados com uma redução na produtividade de grãos no sul da Ásia e na Austrália, e altas produtividades de grãos nas pradarias norte-americanas (Garnett e Khandekar, 1992). Há cada vez mais evidências de um impacto de ENSO na produção agrícola através da sua influência nos padrões climáticos no sudeste dos Estados Unidos (Hansen et al., 1998).

No Brasil a precipitação é um dos elementos do clima mais modificados pela ocorrência deste fenômeno, aumentando ou diminuindo a altura pluviométrica. Diversos trabalhos descrevem os efeitos do fenômeno ENSO nos elementos climáticos e, conseqüentemente, na produção agrícola numa escala regional na

América do Norte e do Sul (Ferreyra et al., 2001; Podesta et al., 1999; Cunha et al., 2001a,b; Berlato e Fontana, 2001; López et al., 2003; Handler, 1984; Phillips et al., 1999; Wannebo e Rosenzweig, 2003).

Ainda de acordo com López et al. (2003) a região árida e semiárida do México tem temperaturas mais altas, em todas as estações do ano, durante os episódios de El Niño do que durante os anos Neutros. A região temperada do México central experimenta reduções na temperatura do ar durante a primavera e o verão nos anos de El Niño, enquanto a região tropical úmida tende a ser mais fria nos anos de El Niño do que nos anos Neutros. Consequentemente, os efeitos das anomalias na temperatura e precipitação refletem na produtividade da safra das culturas.

No entanto, a antecipação do fenômeno ENSO permanece muito incerta, apesar dos projetos que visam monitorar o Oceano Pacífico tropical que são eficazes desde o início dos anos 90 (Smith et al., 2015). As fraquezas dos sistemas de previsão devem derivar de deficiências fundamentais do modelo ou de observações ausentes de variáveis-chave do oceano. Além disso, apesar das previsões dos eventos climáticos do El Niño serem fornecidas e distribuídas frequentemente, os limites da previsibilidade do El Niño ainda são objeto de debate.

1.2.4 Uso de inteligência artificial como modelo de previsão

O conceito de ‘inteligência artificial’ (IA) é amplo, indicando sistemas computadorizados capazes de fazer tarefas de forma automática. Esses sistemas podem ser utilizados em computadores para análise em Ciência de Dados, embarcados em diversas máquinas como: robôs, carros, linhas industriais, tratores, drones, entre outros. Henten (2006), por exemplo, descreveu o estado da arte da utilização de robôs em casas de vegetação para diversas finalidades, como por exemplo o desenvolvimento de um robô colhedor de morango no Japão e outro colhedor de rosas e de folhas de tomate na Holanda.

O uso de IA na agricultura iniciou em 1982, na década de 2000 teve um crescimento muito grande, e hoje segue solucionando diversos problemas nas cadeias produtivas em todo o mundo. Diversos trabalhos utilizam a IA no ramo da agricultura, como Wolfert et al. (2017) os quais fizeram uma revisão sobre a aplicação de IA na

agricultura relacionando a captura de dados por sensores ('big data') e a revolução nos métodos de tomadas de decisões; Pydipati et al. (2006) na detecção de doenças nos citros por meio de imagens digitais; Scharr et al. (2016), com a identificação de genótipos de *Arabidopsis* e de tabaco a partir de visão computacional; Küçük et al. (2016), com a estimativa de estádios fenológicos em arroz a partir de imagens de satélite; e, por fim, Veenadhari et al. (2014) que relacionaram condições climáticas e produtividade de cultivos por meio de IA para entender o impacto de mudanças climáticas na agricultura da Índia.

O termo 'aprendizagem de máquina' (Machine Learning, ML) é uma aplicação corrente de IA baseado no conceito que o sistema computacional tem acesso aos dados da atual atividade que a máquina está fazendo, podendo 'aprender' de forma automática. O aprendizado pode ser feito por diversas técnicas matemáticas e estatísticas podendo ser divididas em métodos: supervisionados, não supervisionados, semi-supervisionados, por reforço, por transdução e 'aprendendo a aprender' (Ayodele, 2010).

1.2.5 Árvores de decisão para classificação

Em particular, a 'Árvore de Decisão para Classificação' (Decision Tree Classifier, DTC) é um método usado com frequência na análise de previsão de dados, o que justifica isso é o fato deste suportar diversos formatos de banco de dados, do binário ao categórico (Zhu et al., 2018). As DTCs apresentam robustez em relação à presença de valores extremos (outliers) ou até mesmo valores com erro (Breiman et al., 1984). Seus algoritmos podem apresentar dois tipos de modelos: classificação e regressão. Sua estrutura muito se assemelha a uma árvore onde cada nó interno é responsável por um teste na característica que está sendo classificada, os ramos são responsáveis por representar o resultado do teste realizado anteriormente e os nós terminais representam as classes geradas no resultado final (Witten et al., 2011).

As DTC foram utilizadas em vários problemas agrícolas como em previsões de secas (Rahmati et al., 2020), estimações de umidade do solo espacializadas e tratamentos de águas residuais (Long et al., 2019), risco de desertificação (Vorovencii, 2015), estimativas de estoques de CO₂ no solo (Mayer et al., 2019), previsão de

produtividade de cultivos (Renuka, 2019), efeito de mudanças climáticas em sistemas agrícolas (Rani et al., 2019), identificação do uso da terra com sensoriamento remoto (Gong et al., 2013), uso de DTC para identificação de estádios fenológicos de cultivos agrícolas e finalmente organização e desenvolvimento de sistemas de suporte à decisão relacionados a bancos de dados agrometeorológicos (Teli et al., 2020).

1.3 Referências

Aceituno P (1988) On the functioning of the Southern Oscillation in the South American sector, part I: surface climate. **Monthly Weekly Review** 116:505– 524.

Alves MB, Souza EB, Repelli CA, Vitorino MI, Ferreira NS (1997) Episódios de La Niña na bacia do oceano pacífico e equatorial e a distribuição sazonal e intra-sazonal das chuvas no setor norte do nordeste brasileiro. **Revista Brasileira de Meteorologia** 12(1):63–76.

Amarasinghe UA, Hoanh CT, D’haeze D, Hung TQ (2015) Toward sustainable coffee production in Vietnam: more coffee with less water. **Agricultural Systems** 136:96-105.

Andrade RGR (1994) **A expansão da cafeicultura em Minas Gerais: da intervenção do estado à liberalização do mercado**. 164 f. Dissertação (Mestrado em Economia) - UFMG/CEDEPLAR, Belo Horizonte.

Angelocci LR, Marin FR, Pilau FG, Righi EZ, Favarin JL (2008) Radiation balance of coffee hedgerows. **Revista Brasileira de Engenharia Agrícola e Ambiental** 12(3):274-281.

Aparecido LEO, Rolim GS, Lamparelli RAC, Souza PS, Santos ER (2017) Agrometeorological Models for Forecasting Coffee Yield. **Agronomy Journal** 109(1):249-258.

Ayodele TO (2010) **Types of Machine Learning Algorithms**, New Advances in Machine Learning, Yagang Zhang, IntechOpen p. 19-48.

Bardin-Camparotto L, Camargo MBP, Moraes JFL (2012) Estimated time of grain ripening of different arabica coffee cultivars for the São Paulo state, Brazil. **Cienc Rural** 42(4):594-599.

Barlow M, Nigam S, Berbery EH (2001) ENSO, Pacific decadal variability, and U.S. summertime precipitation, drought, and stream flow. **J. Clim.** 14:2105–2128.

Berlato MA, Farenzena H, Fontana DC (2005) Associação entre El Niño Oscilação Sul e a produtividade do milho no Estado do Rio Grande do Sul. **Pesq Agrop Brasileira** 40(5):423–432.

Berlato MA, Fontana DC (2001) Impacts of El Niño and La Niña on agricultural production in southern Brazil and the use of climate forecasts in agriculture. In: Cunha GR, Haas JC, Berlato MA (Eds.) **Applications of climate forecasting for better decision making processes in agriculture**. Passo Fundo: EMBRAPA Trigo, p. 217–241.

Berlato MA, Fontana DC (2003) El Niño e La Niña: impactos no clima, na vegetação e na agricultura do Rio Grande do Sul; aplicações de previsões climáticas na agricultura. Porto Alegre: Editora da UFRGS. 110 p.

Breiman L, Friedman J, Stone CJ, Olshen RA (1984) Classification and Regression Trees. The Wadsworth and Brooks-Cole statistics-probability series. Taylor & Francis. 369p.

Bussay A, van der Velde M, Fumagalli D, Seguini L (2015) Improving operational maize yield forecasting in Hungary. **Agric. Syst.** 141:94–106.

Camargo AP (1985) Florescimento e frutificação de café arábica nas diferentes regiões cafeeiras do Brasil. **Pesq Agrop Brasileira** 20(7):831–839.

Camargo AP, Camargo MBP (2001) Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil. **Bragantia** 60(1):65–68.

Camargo MBP (2010) The impact of climatic variability and climate change on arabic coffee crop in Brazil. **Bragantia** 69:239–247.

Casanueva A, Rodríguez-Puebla C, Frías MD, González-Reviriego N (2014) Variability of extreme precipitation over Europe and its relationships with teleconnection patterns. **Hydrol. Earth Syst. Sci.** 18:709–725.

Climate Prediction Center – CPC. (2018). **El Niño – Southern Oscillation (ENSO)**. Disponível em: <<http://www.cpc.ncep.noaa.gov>>

Companhia Nacional de Abastecimento – CONAB (2020) **Acompanhamento da safra brasileira de café: safra 2020**. Brasília, v.6, n.1, Primeiro levantamento Disponível em: <<https://www.conab.gov.br/info-agro/safras/cafe>>

Cunha DR, Dalmago GN, Estefanel D, Pasinato A, Moreira MB (2001a) El Niño-Oscilação Sul e seus impactos sobre a cultura da cevada no Brasil. **Revista Brasileira de Agrometeorologia** 9(1):137-1345.

Cunha G, Dalmago G, Estefanel V (2001b) El Nino Southern Oscillation Influences on Wheat Crop in Brazil. Wheat in a Global Environment. **Wheat in a Global Environment** 445–450.

Damatta FM, Ramalho JDC (2006) Impacts of drought and temperature stress on coffee physiology and production: a review. **Braz J Plant Physiol** 18(1):55–81.

Dilley M, Heyman BN (1995) ENSO and disaster: droughts, floods and El Niño/Southern Oscillation warm events. **Disasters** 19:181–93.

Donat MG, et al. (2014) Changes in extreme temperature and precipitation in the Arab region: Long-term trends and variability related to ENSO and NAO. **Int. J. Climatol.** 34:581–592.

Ferreira RA, Podesta GP, Messina D, Letson J, Guevara E, Meira SA (2001) linked-modeling framework to estimate maize production risk associated with ENSO-related climate variability in Argentina. **Agric. Forest Meteorol.** 107(3):177–192.

Fraser J, Fisher E, Arce A (2014) Reframing ‘crisis’ in fair trade coffee production: trajectories of agrarian change in Nicaragua. **J Agrar Chang** 14(1):52–73.

Garnett E R, Khandekar ML (1992) The impact of large-scale atmospheric circulations and anomalies on Indian monsoon droughts and floods and on world grain yields – a statistical analysis. **Agric. Forest Meteorol.** 61:113–128.

Gershunov A (1998) ENSO influence on intraseasonal extreme rainfall and temperature frequencies in the contiguous United States: implications for long-range predictability. **J. Climate** 11:3192–3203.

Gong P, Wang J, et al. (2013) Finer resolution observation and monitoring of global land cover: first mapping results with Landsat TM and ETM+ data. **International Journal of Remote Sensing** 34(7):2607–2654.

Grimm AM, Barros VR, Doyle ME (2000) Climate Variability in Southern South America associated with El Niño and La Niña events. **J Clim** 13(1):35–57.

Gurgel HC, Ferreira NJ (2003) Annual and interannual variability of NDVI in Brazil and its connections with climate. **International Journal of Remote Sensing** 24:3595–3609.

Haigh T, et al. (2015) Climate Risk Management Mapping the decision points and climate information use of agricultural producers across the U. S. Corn Belt. **Clim. Risk Manag.** 7:20–30.

Handler P (1984) Corn yields in the United States and sea surface temperature anomalies in the equatorial Pacific Ocean during the period 1868–1982. **Agric. Forest Meteorol.** 31(1):25–32.

Hansen JW, Hodges AW, Jones J W (1998) ENSO influences on agriculture in the Southeastern US. **J. Climate** 11:404–411.

Henten EJ (2006) Greenhouse mechanization: State of the art and future perspective. **Acta Horticulturae** 710:55-69.

Hoogenboom G (2000) Contribution of agrometeorology to the simulation of crop production and its applications. **Agric For Meteorol** 103(1/2):137–157.

Iizumi T, Luo J-J, Challinor AJ, Sakurai G, Yokozawa M, Sakuma H, Brown ME, Yamagata T (2014) Impacts of El Niño Southern Oscillation on the global yields of major crops. **Nat. Commun.** 5:3712.

International Coffee Organization – ICO (2020). **Coffee trade statistics**. Disponível em: <<http://www.ico.org>>

Kiladis GN, Diaz HF (1989) Global climatic anomalies associated with extremes in the southern oscillation. **J. Climate** 2:1069–1090.

Küçük Ç, Taskin G, Erten E (2016) Paddy-rice phenology classification based on Machine-Learning methods using multitemporal co-polar x-band SAR images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing** 9(6):2509-2519.

Latif M, Anderson D, Barnett T, Cane M, Kleeman R, Leetmaa A, O'Brien J, Rosati A, Schneider E. (1998) A review of the predictability and prediction of ENSO. **J. Geophys. Res.** 103:14375-14393.

Long B, Xuan X, Yang C, Zhang L, Cheng Y, Wang J (2019) Stability of aerobic granular sludge in a pilot scale sequencing batch reactor enhanced by granular particle size control. **Chemosphere** 225:460-469.

López MT, Izaurralde C, Rosenberg NJ, González ADB, García JS (2003) Modeling El Niño southern oscillation climate impact on Mexican agriculture. **Geofis. Int. Mexico** 42(3):331–340.

Ludescher J, Gozolchiani A, Bogachev MI, Bunde A, Havlin S, Schellnhuber HJ (2014) Very early warning of next El Niño. **Proceedings of the National Academy of Sciences** 111(6):2064-2066.

Marcolan AL, Ramalho AR, Mendes AM, Teixeira CAD, Fernandes CF, Costa JNM, Vieira Júnior JR, Oliveira SJM, Fernandes SR, Veneziano W (2009) Cultivo dos cafeeiros Conilon e Robusta para Rondônia. Porto Velho: EMBRAPA, 67p.

Marengo J (1992) Interannual variability of surface climate in the Amazon basin. **International Journal of Climatology** 12:853– 863.

Martins CC, Reis EF, Busato C, Pezzopane JEM (2006) Crescimento inicial do café conilon (*Coffea canephora* Pierre ex Froehner) sob diferentes lâminas de irrigação. **Engenharia na Agricultura** 14(3):193-201.

Mayer S, Kühnel A, Burmeister J, Kügel-Knabner I, Wiesmeier M (2019) Controlling factors of organic carbon stocks in agricultural topsoils and subsoils of Bavaria. **Soil and Tillage Research** 192:22-32.

Meinke H, Stone RC (2005) Seasonal and inter-annual climate forecasting: the new tool for increasing preparedness to climate variability and change in agricultural planning and operations. **Clim. Change** 70:221–253.

Motha RP, Baier W (2005) Impacts of present and future climate change and climate variability on agriculture in the Temperate Regions: North America. **Clim. Change** 70:137–164.

Nnaji AO (2001) Forecasting seasonal rainfall for agricultural decision-making in northern Nigeria. **Agric. For. Meteorol.** 107:193–205.

Nóia Júnior R, Sentelhas PC (2019) Soybean-maize off-season double crop system in Brazil as affected by El Niño Southern Oscillation phases. **Agricultural Systems** 173:254-267.

Olantínwo RO, Paz JO, Kemerait RCJ, Culbreath AK, Hoogenboom G (2010) El Niño-Southern Oscillation (ENSO): Impact on tomato spotted wilt intensity in peanut and the implication on yield. **Crop Protection** 29:448–453.

Oliveira KMG, et al (2012) Modelagem para a estimativa da orientação de linhas de plantio de cafeeiros. **Engenharia Agrícola** 32(2):293-305.

Ortega AC, Jesus CM (2011) Território café do Cerrado: transformações na estrutura produtiva e seus impactos sobre o pessoal ocupado. **Revista de Economia e Sociologia Rural** 49(3):771-800.

Pereira AR, Camargo AP, Camargo MBP (2008) Agrometeorologia de cafezais no Brasil. Campinas: Instituto Agrônômico, 127p.

Phillips J, Rajagopalan B, Cane M, Rosenzweig C (1999) The role of ENSO indetermining climate and maize yield variability in the U.S. cornbelt. **Int. J.Climatol.** 19:877–888.

Picini AG, Camargo MBP, Ortolani AA, Fazuoli LC, Gallo PB. (1999) Desenvolvimento e teste de modelos agrometeorológicos para a estimativa de produtividade do cafeeiro. **Bragantia** 58(1):157-170.

Podesta GP, Messina CD, Grondona MO, Magrin GO (1999) Associations between grain crop yields in Central-Eastern Argentina and El Niño-Southern Oscillation. **J. Appl. Meteorol.** 38(10):1488–1498.

Pydipati R, Burks TF, Lee WS (2006) Identification of citrus disease using color texture features and discriminant analysis. **Computers and Electronics in Agriculture** 52:49–59.

Rahmati O, Falah F, Dayal KS, Deo RC, Mohammadi F, Biggs T, Moghaddam DD, Naghibi SA, Bui DT (2020) Machine learning approaches for spatial modeling of agricultural droughts in the south-east region of Queensland Australia. **Science of the Total Environment** 699(134230).

Rani S, Sreekesh S, Krishnan P (2019) Effect of climate change on potential evapotranspiration in the upper Beas basin of the western Indian Himalaya. **Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.** XLII-3/W6:51-57.

Rao VB, Hada K (1990) Characteristics of rainfall over Brazil, annual variations and connection with the Southern Oscillation. **Theoretical and Applied Climatology** 42:81– 91.

Ray DK, Gerber JS, MacDonald GK, West PC (2015) Climate variation explains a third of global crop yield variability. **Nat. Commun.** 6:5989.

Renuka TS (2019) Evaluation of machine learning algorithms for crop yield prediction. **International Journal of Engineering and Advanced Technology** 8(6):4082-4086.

Ropelewski CF, Halpert MS (1986) North American precipitation and temperature patterns associated with the El Niño Southern-Oscillation (ENSO). **Mon. Wea. Rev.** 114:2352–2362.

Ropelewski CF, Halpert MS (1987) Global and regional scale precipitation patterns associated with El Niño/Southern Oscillation. **Monthly Weather Review** 115:1606– 1626.

Rowhani P, Lobell DB, Linderman M, Ramankutty N (2011) Climate variability and crop production in Tanzania. **Agric. For. Meteorol.** 151:449–460.

Scharr H, Minervini M, et al. (2016) **Machine Vision and Applications** 27(585).

Simão MLR (1999) **Caracterização espacial da produção cafeeira de Minas Gerais: um estudo exploratório utilizando técnicas de análise espacial e de estatística multivariada**. 246 f. Dissertação (Mestrado em Tratamento da Informação Espacial) - PUC, Belo Horizonte: PUC-MG, 246p.

Sittel MC (1994a) Differences in the means of ENSO extremes for maximum temperature and precipitation in the United States. Center for Ocean-Atmospheric Studies, Florida State Univ., Tallahassee, Fla., **Technical Report** 94-2.

Sittel MC (1994b) Marginal probabilities of the extremes of ENSO events for temperature and precipitation in the Southeastern United States. Center for Ocean-Atmospheric Studies, Florida State Univ., Tallahassee, Fla., **Technical Report** 94-1.

Smith AW (1989) Introduction. In: Clarke RJ, Macrae R (Eds.) *Coffee. Chemistry*, 41p.

Smith N, Kessler WS, Hill K, Carlson D (2015) **Progress in observing and predicting ENSO**. World Meteorological Organization (Bulletin: 64(1)).

Souza Júnior JA, Nechet D, Oliveira MCF, Albuquerque MF (2009) Estudo do comportamento da temperatura e precipitação nos períodos chuvosos e menos chuvosos em Belém-PA em anos de fortes eventos de El Niño e La Niña. **Revista Brasileira de Climatologia** 5:87–101.

Sun X, Renard B, Thyer M, Westr, S, Lang M (2015) A global analysis of the asymmetric effect of ENSO on extreme precipitation. **J. Hydrol.** 530:51-65.

Teli A, Amith A, Bhanu Kaushik K, Gopala Krishna Vasanth K, Sowmya BJ, Seema S (2020) Efficient decision support system on agrometeorological data. **Advances in Intelligent Systems and Computing** 940:875-890.

Thomaziello RA, Fazuoli LC, Pezzopane JRM, Fahl JI, Carelli MLC (2000) Café arábica: “Cultura e técnicas de produção”. **Boletim técnico** 187, Campinas, Instituto Agrônomo 2-6.

Uvo C (1998) **Influence of sea surface temperature on rainfall and runoff in northeastern South America: analysis and modelling**. 120 f. Thesis (Water Engineering) - Lund University, Sweden.

Veenadhari S, Misra B, Singh CD (2014) Machine learning approach for forecasting crop yield based on climatic parameters. **Computer Communication and Informatics (ICCCI)**, International Conference on (pp. 1-5).

Veldkamp TIE, Eisner S, Wada Y, Aerts JCJH, Ward PJ (2015) Sensitivity of water scarcity events to ENSO-driven climate variability at the global scale. **Hydrol. Earth Syst. Sci.** 19:4081–4098.

Veneziano W, Fazuoli LC (2000) Avaliação de cultivares de cafeeiros robusta (*Coffea canephora*) em Rondônia. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, **Anais...** Brasília: EMBRAPA Café, p. 459-461.

Vorovencii I (2015) Assessing and monitoring the risk of desertification in Dobrogea, Romania, using Landsat data and decision tree classifier. **Environmental Monitoring and Assessment** 187(4).

Wannebo A, Rosenzweig C (2003) Remote sensing of US cornbelt areas sensitive to the El Niño-Southern Oscillation-Southern Oscillation. **Int. J. Remote Sens.** 24(10):2055–2067.

Ward, PJ, Bets W, Bouwer LM, Aert, JCJH, Renssen H (2010) Sensitivity of river discharge to ENSO. **Geophys. Res. Lett.** 37:1–6.

Williamson GB, Laurance WF, Oliveira AA, Delamônica P, Gascon C, Lovejoy TE, Pohl L (2000) Amazonian tree mortality during the 1997 El Niño drought. **Conservation Biology** 14: 1538– 1542.

Witten IH (2011) (Ian H, Frank E, Hall MA (Mark A **Data mining: practical machine learning tools and techniques**. [s.l.]) Morgan Kaufmann.

Wolfert S, Ge L, Verdouw C, Bogaardt M-J (2017) Big data in smart farming – A review. **Agricultural Systems** 153:69–80.

Wolter K, Dole R, Smith C (1999) Short-term climate extremes over the continental US and ENSO. Part I: Seasonal temperatures. **J. Climate** 12:3255–3272.

Zhu X, Xu Q, Tang M, Li H, Liu F (2018) A hybrid machine learning and computing model for forecasting displacement of multifactor-induced landslides. **Neural Comput. Appl.** 30(12):3825-3835.

CAPÍTULO 2 - Previsão de eventos de El Niño e La Niña por inteligência artificial

RESUMO - O fenômeno El Niño-Oscilação Sul afeta o clima mundial alterando os padrões de temperatura e de precipitação principalmente em regiões tropicais e de latitudes médias, influenciando fortemente as atividades e a produtividade agrícola. O Índice Oceânico Niño (ONI) do 'National Oceanic and Atmospheric Administration' (NOAA) dos Estados Unidos, descreve e monitora a intensidade de ENSO a partir de medidas da temperatura do oceano. Se $ONI \leq -0,5$; $-0,5 < ONI < 0,5$ e $ONI \geq 0,5$; o trimestre é classificado como La Niña, neutro e El Niño, respectivamente. A previsão destes eventos é feita por modelagem em grandes centros meteorológicos mundiais por modelos de acoplamento atmosfera-oceano, entretanto, nenhum artigo foi encontrado utilizando modelagem por árvore de decisão (DTC) para fins de previsão de fenômenos de El Niño e La Niña. Esse tipo de modelagem requer capacidade e tempo computacional muito menor, podendo ser suficientemente acurado para fins agrícolas. Dessa forma, o objetivo deste trabalho é a previsão antecipada de que se um ano será de El Niño, La Niña ou neutro utilizando a técnica de DTC a partir de dados de ONI do período de 1950 a 2018. Para tanto foram utilizados como variáveis de entrada para a DTC os valores trimestrais de ONI com dois anos de antecedência à previsão (definida sempre como dezembro). A DTC apresentou uma acurácia de 91%, 92% e 83% para previsões de anos de El Niño, La Niña e anos neutros, respectivamente, no período de treinamento e 80%, 93% e 73%, respectivamente, para o período de validação. Os trimestres de ONI selecionados foram março-abril-maio e outubro-novembro-dezembro do ano anterior e janeiro-fevereiro-março do ano atual, permitindo uma previsão com 9 meses de antecedência com uma acurácia média de 82% (validação).

Palavras-Chave: anomalias climáticas, aprendizagem de máquina, ENSO, primavera boreal

Forecasting El Niño and La Niña events using artificial intelligence

ABSTRACT - The El Niño-Southern Oscillation (ENSO) phenomenon affects the global climate by changing temperature and precipitation patterns mainly in tropical climatic regions and media latitudes, strongly influencing agricultural activities and crop yields. The Niño Oceanic Index (ONI) of the US National Oceanic and Atmospheric Administration (NOAA) describes and monitors ENSO intensity from ocean temperature measurements. If $ONI \leq -0.5$, $-0.5 < ONI < 0.5$ and $ONI \geq 0.5$, the quarter is classified as La Niña, neutral and El Niño, respectively. The prediction of ENSO events is made by modeling at major global weather centers by atmosphere-ocean coupling models; however, no articles was found using decision tree classifier (DTC) for ENSO forecasting purposes. This type of modeling requires much less computational time and capacity and can be sufficiently accurate for agricultural purposes. Thus, the objective of this research is forecast as early as possible if the

year would be El Niño, La Niña or neutral using a decision tree classifier (DTC) using ONI data from 1950 to 2018. We use as input variables for DTC or quarterly ONI values from 2 years prior the data of forecasting (always December). The DTC showed an accuracy of 91%, 92% and 83% for display of El Niño, La Niña and neutral years respectively without training period and 80%, 93% and 73% respectively for validation. The selected ONI quarters were March-April-May and October-November-year of the previous year and January-February-March of the current year, allowing a 9-month advance forecast with an average accuracy of 82% (validation).

Keywords: climate anomalies, machine learning, ENSO, boreal spring

2.1 Introdução

A variabilidade climática natural é impulsionada por inúmeros processos, mas o mais importante é o fenômeno El Niño Oscilação Sul (ENSO) (Clarke, 2008; Wang et al., 2012). O ENSO é um fenômeno atmosférico caracterizado por anomalias na temperatura em áreas tropicais do Oceano Pacífico, causando mudança nos padrões de vento e precipitação em regiões tropicais e latitudinais (Souza Júnior et al., 2009). O ENSO possui duas fases distintas: El Niño, uma fase quente, e La Niña, uma fase fria (Berlato et al., 2005). O período do ciclo em que nem El Niño nem La Niña ocorrem é classificado como fase neutra, a qual apresenta condições climáticas intermediárias.

O fenômeno ENSO é rastreado e quantificado pelo Índice Oceânico Niño (Oceanic Niño Index, ONI) que é definido como a média das anomalias da temperatura da superfície do mar (Sea Surface Temperature, SST) em determinados pontos do Oceano Pacífico (Ludescher et al., 2014). Os pontos de coleta de informações no oceano são chamados de 'Niño 3.4' correspondendo a área formada entre 5° S e 5° N, e entre 120° O e 170° O. Estabeleceu-se que um episódio de El Niño ocorre quando o índice está acima de 0,5 °C por um período de pelo menos 5 meses, assim como um episódio de La Niña ocorre quando este índice está abaixo de -0,5 °C por um mesmo período de tempo (Climate Prediction Center, 2012).

Fortes episódios de El Niño ou La Niña podem causar grandes impactos no mundo (Ludescher et al., 2014) como tsunamis, tempestades, secas ou chuvas anormais (Zhang et al., 2006). Como já foi relatado por Ronghui e Yifang (1989) na seca causada na península da Indochina e no sul da China durante o verão, por

Chimeli et al. (2008) na correlação direta entre os efeitos das anomalias da SST e o preço do milho ou por Bastianini et al. (2018) no impacto do ENSO nas áreas de plantações de café na Colômbia. Por isso, sistemas de alerta precoce em cooperativas, instituições governamentais, empresas e mesmo produtores, que tenham previsões de qualidade de ENSO são altamente desejáveis.

Embora as previsões do ENSO usando modelos acoplados atmosfera-oceano (MAAO) geralmente superem as dos modelos estatísticos (Luo et al., 2008), os sistemas MAAO necessitam de alta capacidade de processamento devido à necessidade de simulação de muitos cenários (McPhaden et al., 2006) e, ainda assim, não fornecem uma previsão acurada de ENSO para prazos de entrega a partir de um ano (Tang et al., 2018).

A evolução de modelos atuais, o aprimoramento de sistemas de observação e análise, a maior resolução espacial e a utilização de séries temporais mais longas permitem fazer melhores previsões de episódios de El Niño e La Niña. E, por isso, a construção de modelos estatísticos determinísticos, a partir de séries temporais observadas, tem se tornado cada vez mais comum, principalmente em aplicações climáticas regionais (Gavrilov et al., 2019).

Tendo uma longa série de observações é possível tornar a série temporal estacionária aumentando a probabilidade de previsões acuradas (Armstrong et al., 2005). Entretanto, os modelos estatísticos continuam tendo problemas em relação a acurácia devido à alta variabilidade espacial e temporal, tornando esses tipos de modelos úteis somente em regiões específicas. Assim, os métodos de Inteligência Artificial (IA) vêm preenchendo estas lacunas devido ao grande poder de previsões acuradas com grande poder computacional associado a hardwares simples.

Os métodos de IA são considerados importantes quando os sistemas em estudo são complexos e com alta variabilidade dos dados (Witten e Frank, 2005; Barsegyan et al., 2007). Com o advento do 'big data' (grande disponibilidade de dados de forma razoavelmente organizada) a IA teve um impacto dramático em muitos domínios do conhecimento humano (Austin et al., 2013; Arsanjani et al., 2014) tornando possível estimativas e previsões acuradas de forma relativamente simples.

As técnicas de aprendizagem de máquina (Machine Learning, ML) são bastante robustas e com facilidade conseguem analisar os padrões e regras em grandes

conjuntos de dados de múltiplas variáveis preditoras que tem relações não lineares com a variável alvo (Chandra et al., 2019). Em particular, a ‘Árvore de Decisão para Classificação’ (Decision Tree Classifier, DTC) é um método usado com frequência na análise de previsão de dados (Zhu et al., 2018).

O objetivo básico de induzir uma árvore de decisão é produzir um modelo de previsão preciso (Breiman et al., 1984), esse método apresenta robustez em relação à presença de valores extremos (outliers) ou até mesmo valores com erro, além de capacidade de rastreo e bom desempenho. Por isso, as DTC já foram utilizadas para organização e desenvolvimento de sistemas de suporte à decisão relacionados a bancos de dados agrometeorológicos (Teli et al., 2020).

Mas poucos artigos na literatura utilizam técnicas de Machine Learning (ML) relacionados à ocorrência de ENSO. Silva e Hornbergen (2019) relacionaram ENSO com a distribuição de chuvas no Sri Lanka utilizando DTC; e Wei et al. (2019) que realizaram previsões de chuvas intensas no leste da Ásia utilizando DTCs em séries históricas de ENSO e precipitação. Entretanto, não foi encontrado nenhum trabalho que utilizasse DTC para previsão de eventos ENSO. Devido a isso, o presente estudo utiliza DTC para prever condições de ENSO a partir de dados da ONI, de forma a obter um modelo simples e acurado para previsão de eventos quentes e frios do El Niño Oscilação Sul.

2.2 Material e métodos

Utilizamos dados trimestrais do Índice Oceânico Niño (ONI) para o El Niño (EN), La Niña (LN) e para os anos neutros (NE) dos ciclos ENSO de 1950-2018, fornecidos pela Administração Nacional Oceânica e Atmosférica (NOAA). Os ciclos de ENSO no Oceano Pacífico tropical são detectados por vários métodos, incluindo sensoriamento remoto por satélite, análises do nível do mar e boias ancoradas, flutuantes e descartáveis (Climate Prediction Center, 2012). O ONI é o principal indicador da NOAA para monitorar EN e LN. Ele rastreia as temperaturas médias da superfície do mar (SST) trimestralmente no Pacífico tropical leste-central entre 5° N a 5° S em latitude e 170° W a 120° W em longitude (índice Niño 3.4) proposto por Trenberth (1997) (Figura 1). O ENSO é caracterizado com base na data em que os eventos estão

maduros/sazonados. A SST, com 125 m de profundidade no Pacífico centro-oriental, carrega informações relevantes e oferece uma fonte de previsão antecipada da amplitude do ENSO, informando como as anomalias do SST se desenvolverão até que o ENSO seja totalmente desenvolvido para ser previsto (Pinault, 2016). Os cientistas chamam a área de Niño 3.4, sendo importante delimitar a região de estudo uma vez que é aceito que o ENSO exiba um comportamento diferente quando observado nas regiões do Pacífico central e/ou Pacífico oriental (Kao e Yu, 2009).




Figura 1. A) Exemplo de evento de El Niño no oceano pacífico (Fonte NOAA) (as cores representam a temperatura do oceano, sendo as cores avermelhadas mais quentes que as demais); B) Localização da região denominada Niño 3.4 onde se localiza os sensores de temperatura para estimação do Índice Oceânico Niño (ONI).

A NOAA considera que as condições EN estão presentes quando o ONI é $+0,5$ ou superior, indicando que o Pacífico tropical leste-central está significativamente mais quente que o normal. As condições do LN existem quando o Índice Oceânico Niño é igual ou inferior a $-0,5$, indicando que a região está mais fria do que o habitual (Climate Prediction Center, 2012).

Árvores de decisão para classificação são métodos supervisionados não paramétricos usados para classificação e regressão. O objetivo desses métodos é criar um modelo que estime valores de um TARGET (variável dependente)

aprendendo simples regras de decisão oriundas das FEATURES (variáveis independentes). Neste caso o TARGET é o valor médio anual de ONI, que finaliza em dezembro e as FEATURES são os valores de ONI trimestrais dois anos antes.

A forma de entrada dos dados para a DTC foi feita da seguinte maneira: utilizou-se um ano de dados trimestrais anteriores ao período de dezembro do ano que se quer fazer a previsão somando-se aos 12 trimestres do ano atual, totalizando 24 trimestres como variáveis de entrada para previsão do ano corrente (Figura 2).




Figura 2. Esquema das variáveis de entrada no modelo de árvore de decisão para a previsão se o ano atual será de El Niño, La Niña ou neutro. Legenda: as letras representam os meses, por exemplo, DJF-A: Dezembro, Janeiro e Fevereiro do ano anterior ('-A'); NDJ: Novembro, Dezembro e Janeiro do ano atual.

As DTCs constroem a árvore de forma recursiva, de cima para baixo (Han e Kamber, 2001). Inicia com o conjunto de treinamento, que é dividido de acordo com um teste sobre uma das FEATURES, formando-se subconjuntos mais homogêneos em relação ao TARGET. Esse procedimento é repetido até que se consiga conjuntos de exemplos bem homogêneos, para os quais seja possível atribuir um único valor para a variável dependente.

As DTCs apresentam as vantagens de serem simples e de fácil visualização, requerem pouca preparação dos dados, podem tratar dados numéricos e categóricos e são modelos robustos, possibilitando validar os modelos usando testes estatísticos, mesmo quando algumas pressuposições são violadas. Porém, como resultados, podem ser geradas árvores complexas, mas existem alguns mecanismos que podem evitar esse problema, como o ajuste do número mínimo de amostras para cada nó e/ou o número máximo de nós da árvore. Mas, para evitar esse problema normalmente utiliza-se um número grande e balanceado de dados e faz-se a seleção de FEATURES adequadas para que a representação do sistema em estudo seja feita de forma parcimoniosa.

O algoritmo de DTC, levando em conta os valores médios e a variabilidade anual dos dados trimestrais do ONI, seleciona quais trimestres serão mais importantes para a previsão anual do fenômeno ENSO. O critério utilizado para escolher a variável independente que divide o conjunto de exemplos em cada repetição é o aspecto principal do processo de indução. Dentre os critérios mais conhecidos e usados, cita-se o índice de ganho de informação ou entropia (Quinlan, 1993), relacionado com a (im)pureza dos dados, que foi o critério escolhido para esse trabalho. A entropia é uma medida da falta de homogeneidade dos dados de entrada em relação à sua classificação. Por exemplo, se a amostra for completamente homogênea, então a entropia é zero, e se apresentar entropia máxima (igual a 1) significa que o conjunto de dados é heterogêneo (Mitchell, 1997; Coimbra, 2014).

A indução da DTC foi realizada de forma binária, com dois ramos a partir de cada nó interno. Para evitar que o modelo ficasse muito específico para o conjunto de treinamento (sobre-ajustamento ou “overfitting”), o que comprometeria a sua generalização e o desempenho com novos exemplos, foram adotadas dois critérios de parada do algoritmo de indução. A primeira regra limitou a profundidade da árvore, permitindo-a ter no máximo cinco níveis (o nó raiz é considerado estar no nível zero). A segunda regra limitou a fragmentação do conjunto de treinamento, requerendo um mínimo de quatro exemplos em cada nó para a busca de uma nova divisão e pelo menos quatro exemplos em cada nó folha.

Além dos critérios de parada, denominadas de pré-poda, foi realizado um procedimento de pós-poda, após a indução da árvore completa. Junto com essa árvore completa, foram avaliadas suas possíveis sub-árvores e escolhida a menor sub-árvore (menor complexidade) com a menor taxa de erro sobre o conjunto de treinamento, tendo em vista que as árvores complexas podem ser piores do que as árvores mais simples na previsão de novos dados devido ao ‘overfitting’ (Phillips et al., 2017).

A taxa de erro e a acurácia são as medidas de avaliação mais comuns para árvores de decisão (Han e Kamber, 2001; Witten e Frank, 2005). O erro de previsão de um modelo é definido como o erro quadrado esperado para novas previsões e para classificação como a probabilidade de classificar incorretamente novas observações (De’ath e Fabricius, 2000). Calcular a taxa de erro sobre o conjunto de treinamento

normalmente resulta em uma estimativa altamente otimista, devido à especialização do modelo com respeito aos exemplos. Para contornar esse problema, o modelo foi dividido aleatoriamente em dois conjuntos independentes, um de treinamento e outro de validação, com 80 e 20% dos dados, respectivamente (Han e Kamber, 2001).

Além dessas medidas, foi produzida a matriz de confusão da árvore de decisão, a qual oferece meios efetivos para a avaliação do modelo com base em cada classe (Monard e Baranauskas, 2003), entretanto os resultados foram apresentados em gráficos tipo 'sankey' (fluxograma). Cada elemento da matriz mostra o número de exemplos, sendo a classe observada em linha e a classe predita em coluna. A partir da matriz gerada foram extraídos os valores verdadeiros positivos (VP), que ocorrem quando o modelo prevê um caso positivo corretamente, falsos positivos (FP) que são aqueles casos que o em que o modelo classifica como um determinado ENSO quando na verdade não é, falso negativo (FN) quando o modelo indica que não é um determinado ENSO mas na verdade é, e por fim, o verdadeiro negativo (VN) que é quando o modelo diz que não é determinado ENSO e ele acerta (Hothorn et al., 2005).

Os valores de VP, VN, FP e FN foram determinados da seguinte forma a partir das tabelas de confusão (Figura 3).

A)		EST			
Para EN			EN	LN	NE
OBS	EN		VP	FN	FN
	LN		FP	VN	VN
	NE		FP	VN	VN

B)		EST			
Para LN			EN	LN	NE
OBS	EN		VN	FP	VN
	LN		FN	VP	FN
	NE		VN	FP	VN

C)		EST			
Para NE			EN	LN	NE
OBS	EN		VN	VN	FP
	LN		VN	VN	FP
	NE		FN	FN	VP

Figura 3. Esquema de tabelas de confusão utilizado para determinação de verdadeiro positivo (VP), verdadeiro negativo (VN), falso positivo (FP) e falso negativo (FN) na análise de aprendizagem de máquina por árvores de decisão, para os casos de El Niño (EM) (A), La Niña (B) e anos neutros (NE) (C). Sendo: OBS os valores observados na série histórica e EST os valores estimados pela árvore de decisão.

Algumas estatísticas, descritas por Stojanoviü et al. (2014) foram calculadas de duas formas: como testes de rastreamento ('screening') e como testes diagnósticos.

Os testes de rastreamento são aqueles feitos para se conhecer as proporções das classificações que já ocorreram. Neste caso o valor preditivo positivo (VPP) é a proporção de classificações corretas das árvores de decisão entre todas as classes corretas de mesmo tipo (equação 1) e o valor preditivo negativo (VPN) é a proporção de classificações erradas entre todas as classes erradas de mesmo tipo (equação 2).

Já os testes diagnósticos, relacionados aos valores estimados, são aqueles feitos para se conhecer a probabilidade das detecções para o futuro: A sensibilidade avalia a capacidade da árvore de decisão detectar uma determinada classe de ENSO quando ela é realmente a correta (equação 3). A especificidade avalia a capacidade da árvore de decisão em não detectar uma determinada classe quando ela não é realmente e correta (equação 4). A acurácia é o desempenho geral do modelo de árvores de decisão (equação 5).

$$\text{Valor preditivo positivo: } VPP = \frac{VP}{(VP+FP)} \quad (1)$$

$$\text{Valor preditivo negativo: } VPN = \frac{VN}{(VN+FN)} \quad (2)$$

$$\text{Sensibilidade} = \frac{VP}{(VP+FN)} \quad (3)$$

$$\text{Especificidade} = \frac{VN}{(VN+FP)} \quad (4)$$

$$\text{Acurácia} = \frac{(VN+VP)}{n} \quad (5)$$

Todas as análises e organização dos dados foram realizadas utilizando linguagem de programação Python 3.7.4, com as seguintes bibliotecas: numpy, pandas, statsmodels, sklearn e os gráficos com matplotlib, graphviz e pysankey.

2.3 Resultados e discussão

A previsibilidade da ENSO depende do período em que é estimado (Chen et al., 2004; Chen et al., 1995; Kirtman e Schopf, 1998; Balmaseda et al., 1995). Um período de estudo de 68 anos é longo o suficiente para que as previsões sejam estatisticamente robustas, diferente de trabalhos de alguns autores que são baseados em previsões das últimas duas ou três décadas apenas (Goswami e Sukla, 1991; Chen et al., 1995). Na avaliação da série temporal das anomalias sazonais de SST observadas do Niño 3.4 durante o período de 1950 a 2018 pode-se avaliar qualitativamente a variabilidade do ENSO, a qual em vários momentos demonstra um padrão multi-decadal (Figura 4), com picos de El Niño, La Niña e neutros mais ou menos constantes.

Durante os anos de 1950 a 2018, ocorreram pelo menos moderados eventos de El Niño em 1986/87, 1996/97 e 2014/15 da mesma forma para eventos de La Niña em 1954/55, 1974/75 e 1998/99. Os eventos mais fracos, próximos à neutralidade, de El Niño ocorreram em 1991/92 e 2001/02, já para La Niña, os mesmos ocorreram em 1955/56, 1985/86 e 2006/07 (Figura 4).

Houve frequência de anos neutros durante a análise da série temporal, com sequências marcadas entre os anos de 1959/62, 1977/81 e 2003/06, indicando um período multi-decadal com estes eventos acontecendo em intervalos de 10 ou 20 anos. A condição de anos neutros apresenta menor dispersão dos dados de ONI quando comparada com as condições de anos de El Niño e La Niña (Figura 4).

Apesar das fortes e regulares oscilações na década de 60, houve períodos sem muita atividade de El Niño ou La Niña, como no fim da década de 70 e início de 80. Se definirmos um El Niño como um evento quente quando o índice de anomalias ONI for maior que 0,5 °C, e um La Niña como um evento frio da mesma amplitude, verifica-se que houve 15 eventos de El Niño e 15 eventos de La Niña desde 1950 até 2018.




Figura 4. Índice Niño Oceânico (ONI) anual (Fonte NOAA). Um ano é classificado como La Niña quando o ONI médio anual $\leq -0,5$. Quando o valor de ONI médio anual $\geq 0,5$ o ano é classificado como El Niño. Anos neutros ocorrem quando $-0,5 \leq \text{ONI médio} \leq 0,5$. As barras verticais indicam o desvio padrão de ONI trimestrais por ano.

Estratificando a análise para a escala trimestral, existiu uma variabilidade menor do ONI durante o meio do ano civil, verificada pelo menor desvio padrão da marcha sazonal. A estação de outono/inverno do Hemisfério Sul apresentou menor desvio padrão em relação às estações de primavera/verão. De acordo com Ham et al. (2019), o índice ONI possui uma correlação alta com quase todas as estações-alvo, influenciando em previsões mais robustas nas estações entre o final da primavera e o outono boreal, entretanto, para as condições austrais existe uma inversão fazendo com que os trimestres mais informativos para modelos de ML sejam os de maiores variabilidades, entre agosto e março. Este fato foi corroborado pelo presente estudo, pois o trimestre mais importante para previsão da condição ENSO anual foi o de janeiro-fevereiro-março (Figura 5).

A primavera boreal (entre março e junho) é vista como uma barreira na previsão do ENSO por causar uma queda de habilidade na persistência (diminuição dos desvios padrões) em todas as previsões de ONI pelos modelos (Chen et al., 2004). O mesmo ocorre no hemisfério sul, porém, na estação do outono (entre março e junho) (Figura 5).

De forma inversa, a primavera austral (entre setembro e dezembro) ocorre o aumento dos desvios padrões de ONI permitindo maior variabilidade das informações nas entradas da árvore de decisão tornando este período informativo para os modelos de ML (Figura 5).

A diminuição dos desvios padrões entre maio junho provavelmente está relacionada à falta de eventos muito fortes, como os eventos do El Niño de 1991/92 e 2001/02 e também se deve à dependência sazonal do ciclo de descarga/recarga do conteúdo de calor equatorial (ou nível do mar), que conduz a anomalia da SST por 6 a 8 meses e desempenha um papel crucial no ENSO (McPhaden, 2003; Meinen e McPhaden, 2000; Jin, 1997).




Figura 5. Índice Niño Oceânico (ONI) trimestral do período entre 1950 e 2018 (Fonte NOAA). Um trimestre é classificado como La Niña quando o ONI daquele período $\leq -0,5$. Quando o valor de ONI trimestral $\geq 0,5$ o trimestre é classificado como El Niño. Trimestres neutros ocorrem quando $-0,5 \leq \text{ONI médio} \leq 0,5$. As barras verticais indicam o desvio padrão de ONI por ano. As letras indicam o trimestre, por exemplo: DJF: dezembro, janeiro e fevereiro; JFM: janeiro, fevereiro e março, seguindo-se dessa forma.

A análise do modelo de árvore de decisão mostrou que alguns trimestres de índice ONI, incluindo janeiro-fevereiro-março (JFM), março-abril-maio do ano anterior (MAM-A) e outubro-novembro-dezembro do ano anterior (OND-A) tiveram maior influência na predição de eventos do ENSO (Figura 6). O primeiro preditor (JFM) está relacionado ao primeiro trimestre do ano previsto e os outros dois preditores utilizados para a previsão do ONI são relacionados a trimestres do ano anterior ao previsto, demonstrando a antecipação da previsão e confirmando que a previsão dos eventos de ONI é amplamente determinada pelas condições iniciais oceânicas (Chen et al., 2004) na primavera-verão austrais.

A primeira divisão é baseada no trimestre de JFM, o qual foi o preditor mais poderoso e utilizado pelo modelo para todas as previsões, indicando que o modelo

consegue prever um evento anual até o terceiro mês do ano corrente, ou ainda, 9 meses antes do término do ano. O nó esquerdo é fortemente homogêneo e não é posteriormente dividido, sendo classificado como um ano de La Niña. Continuando com o ramo direito, compreendendo o trimestre de MAM do ano anterior, ele agora está fortemente dividido, finalizando com uma classificação de anos neutros à direita e mantendo a divisão no ramo da esquerda, o qual repete uma classificação de anos neutros à esquerda nesse momento. O processo de divisão é fortemente repetido no nó da direita, com a finalização da árvore de decisão classificando anos de El Niño à esquerda e anos neutros à direita.

Esse atraso de uma a duas estações ocorre porque a atmosfera leva cerca de duas semanas para responder às anomalias da SST no Pacífico tropical e, em seguida, o oceano integra a força associada à ponte atmosférica nos próximos meses (Alexander et al., 2002). As respostas da árvore de decisão foram acuradas e robustas, tanto para o período de treinamento como para o de validação, indicando que a proposta para previsão de ENSO anual foi bem-sucedida.




Figura 6. Análise em árvore de decisão para a previsão de eventos El Niño Oscilação Sul anuais em função de dos Índices Niño Oceânico (ONI) trimestrais. Símbolos: JFM: janeiro-fevereiro-março; MAM-A: março-abril-maio do ano anterior; OND-A: outubro-novembro-dezembro do ano anterior.

No período de treinamento, dos 10 anos observados de EN, 5 foram previstos com sucesso e outros 5 foram previstos como NE. De forma semelhante, dos 9 anos de LN, 6 foram previstos com sucesso como LN e 3 como NE. Por fim, dos 34 anos observados como NE, 33 foram previstos como NE e 1 ano como LN (Figura 7).




Figura 7. Diagrama de sankey para representação da matriz de confusão para o período de treinamento para as previsões de anos de El Niño (EN), La Niña (LN) e neutros (NE).

Portanto, apesar dos anos de EN terem uma especificidade de 100%, pelo fato de todos os anos preditos como EN serem de fato oriundos deste evento, a sensibilidade do modelo na previsão de EN é baixa, porque metade dos anos deste evento foram previstos incorretamente como eventos NE e, por isso, sua sensibilidade é de 50%; resultando, portanto, em uma acurácia de 91%. Caso semelhante ocorre para anos de LN, que apresenta 98% de sensibilidade e 67% de especificidade, resultando em 92% de acurácia. O contrário ocorre para anos NE, que apresentam uma especificidade baixa (58%) por prever anos de EN e de LN como se fossem anos NE, porém, sua sensibilidade é de 97% por prever corretamente a maioria de seus próprios eventos; apresentando no final uma acurácia de 83% (Tabela 1).

Já no período de validação, dos 5 casos de LN, 4 foram previstos corretamente como LN e 1 como NE, o que aumenta a especificidade de eventos de LN. Dos 5 casos de EN, somente 2 foram previstos como EN e 3 como NE. E por fim, com a maior taxa de acertos, dos 5 anos NE, os 5 foram previstos corretamente como NE, resultando em 100% de sensibilidade do modelo para este evento, porém, como foram previstos 4 eventos como NE erroneamente, a especificidade para a validação em anos NE foi de 60% (Figura 8).




Figura 8. Diagrama de sankey para representação da matriz de confusão para o período de validação para as previsões de anos de El Niño (EN), La Niña (LN) e neutros (NE).

No período de treinamento ($n = 53$ anos) a árvore de decisão previu os eventos ENSO com acurácia geral de 89%, e no período de validação ($n = 15$) igual a 82% (Tabela 1, Figura 9). Esses resultados são semelhantes aos obtidos por outros autores como Nooteboom et al. (2018) que associaram redes neurais artificiais com modelos ARIMA. Entretanto, nossos resultados são decorrentes de uma aproximação mais simples com o mesmo desempenho.




Figura 9. Frequências de classes observadas e preditas de El Niño, La Niña e anos neutros pelo modelo de Árvore de Decisão para 68 anos divididos em 53 anos para treinamento (A), e 15 anos para validação (B).

A maior precisão do modelo (Valor preditivo positivo, Tabela 1) da árvore de decisão, ou seja, a capacidade de prever corretamente a condição (verdadeiros-positivos) foi na previsão de anos de El Niño (100%), seguida por anos de La Niña (86%) e anos neutros (80%). No período de validação os resultados foram semelhantes com 100%, 100% e 56%, respectivamente.

Quanto mais sensível a classificação, maior seu VPN, ou seja, há mais segurança de que a árvore de decisão não errou. Normalmente a sensibilidade e a especificidade são inversas. Quanto mais específico o modelo, mais ele está com 'overfitting', entretanto, para a presente análise, os valores próximos a 100, tanto no treinamento como na validação, oferecem muita segurança na resposta da árvore de decisão porque utilizamos todos os dados disponíveis da série histórica de ONI. Neste caso, quanto mais específico melhor ($\approx 100\%$). A especificidade foi menor em relação aos anos de NE, ao redor de 60% provavelmente devido à maior variabilidade dos dados no período de 1950 a 2018.

Tabela 1. Desempenho da análise de árvore de decisão nos períodos de treinamento e de teste para previsão de eventos de El Niño (EN), La Niña (LN) e de anos neutros (NE). Legenda TP= verdadeiro positivo, FP= falso positivo, TN= verdadeiro negativo, FN= falso negativo e n=número de dados.

	Treinamento				Validação			
	EN	LN	NE	Média	EN	LN	NE	Média
Estatísticas	%				%			
Valor preditivo positivo	100	86	80	89	100	100	56	85
Valor preditivo negativo	90	93	92	92	77	91	100	89
Acurácia	91	92	83	89	80	93	73	82
Sensibilidade	50	67	97	71	40	80	100	73
Especificidade	100	98	58	85	100	100	60	87
Frequências observadas	EN	LN	NE	Soma	EN	LN	NE	Soma
TP=	5	6	33	44	2	4	5	11
FP=	0	1	8	9	0	0	4	4
TN=	43	43	11	97	10	10	6	26
FN=	5	3	1	9	3	1	0	4
n=	53	53	53		15	15	15	

2.4 Conclusão

A previsão do sinal ENSO é mais robusta nas estações entre o final da primavera e o outono boreal e, os preditores mais importantes para a previsão de anos de El Niño e La Niña são, na grande maioria, trimestres de anos anteriores à previsão.

Os resultados indicam que é possível fazer uma previsão dos eventos quentes e frios do El Niño Oscilação-Sul apenas com dados da temperatura da superfície do mar, sendo possível a utilização de árvores de decisão para previsão de condições de anos de El Niño, La Niña e neutros com acurácia média de 84%.

A previsão foi possível com 9 meses de antecipação, utilizando dados trimestrais do Índice Niño Oceânico (ONI) dos períodos de março-abril-maio e outubro-novembro-dezembro do ano anterior e janeiro-fevereiro-março do ano corrente.

2.5 Referências

- Alexander MA, Blade I, Newman M, Lanzante JR, Lau N-C, Scott JD (2002) The atmospheric bridge: the influence of ENSO teleconnections on air-sea interaction over the global oceans. **J. Climate** 15:2205-2231.
- Armstrong JS, Collopy F, Yokum JT (2005) Decomposition by Causal Forces: a Procedure for Forecasting Complex Time Series. **Int. J. Forecasting** 21:25-36.
- Arsanjani R, Dey D, Khachatryan T, Shalev A, Hayes SW, Fish M (2014) Prediction of revascularization after myocardial perfusion SPECT by machine learning in a large population. **J Nucl Cardiol.** 22(5):877-84.
- Austin PC, Tu JV, Ho JE, Levy D, Lee DS (2013) Using methods from the data-mining and machine-learning literature for disease classification and prediction: a case study examining classification of heart failure subtypes. **J Clin Epidemiol** 66(4):398-407.
- Balmaseda MA, Davey MK, Anderson DLT (1995) Decadal and seasonal dependence of ENSO prediction skill. **J Clim.** 8:2705-2715.
- Barsegyan AA, Kupriyanov MS, Stepanenko VV, Kholod II (2007) Data Analysis Technologies. Data Mining, Visual Mining, Text Mining, OLAP. St. Petersburg: BHV-Petersburg, 384 p.
- Bastianin A, Lanza A, Manera M (2018) Economic impacts of El Niño southern oscillation: evidence from the Colombian coffee market. **Agricultural Economics** 1:3-17.
- Berlato MA, Farenzena H, Fontana DC (2005) Associação entre El Niño Oscilação Sul e a produtividade do milho no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira** 40(5):423-432.
- Breiman L, Friedman J, Stone CJ, Olshen RA (1984) Classification and Regression Trees. The Wadsworth and Brooks-Cole statistics-probability series. Taylor & Francis. 369p.
- Chandra A, Mitra P, Dubey SK, Ray SS (2019) Machine Learning Approach for Kharif Rice Yield Prediction Integrating Multi-Temporal Vegetation Indices and Weather and Non-Weather Variables. **ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences.** 423:187-194.
- Chen D, Cane MA, Kaplan A, Zebiak SE, Huang D (2004) Predictability of El Niño over the past 148 years. **Nature** 428(6984):733.
- Chen D, Zebiak SE, Busalacchi AJ, Cane MA (1995) An improved procedure for El Niño forecasting: implications for predictability. **Science** 269:1699-1702.

Chimeli A, Souza Filho F, Holanda M, Petterini F (2008) Forecasting the impacts of climate variability: lessons from the rainfed corn market in Ceará, Brazil. **Environ Dev Econ** 13(2):201-227.

Clarke AJ (2008) An Introduction to the Dynamics of El Niño and the Southern Oscillation (Elsevier Academic Press, Londres).

Climate Prediction Center – CPC (2012) **Frequently asked questions about El Niño and La Niña**. Disponível em: <https://www.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ensofaq.shtml#forecasts>

Coimbra R, Rodriguez-Galiano V, Olóriz F, Chica-Olmo M (2014) Regression trees for modeling geochemical data - An application to Late Jurassic carbonates (Ammonitico Rosso), **Computers & Geosciences** 73:198-207.

De'ath G, Fabricius KE (2000) Classification and Regression Trees: A Powerful yet Simple Technique for Ecological Data Analysis. **Ecology** 81:3178-3192.

Gateau-Rey L, Tanner EVJ, Rapidel B, Marelli J-P, Royaert S (2018) Climate change could threaten cocoa production: Effects of 2015-16 El Niño-related drought on cocoa agroforests in Bahia, Brazil. **PLoS ONE** 13(7):e0200454.

Gavrilov A, Seleznev A, Mukhin D, Loskutov E, Feigin A, Kurths J (2019). Linear dynamical modes as new variables for data-driven ENSO forecast. **Clim Dyn** 52(3-4):2199-2216.

Goswami BN, Sukla J (1991) Predictability of a coupled ocean-atmosphere model. **J. climate** 4:3-22.

Ham YG, Kim JH, Luo J-J (2019) Deep learning for multi-year ENSO forecasts. **Nature** 573.

Han J, Kamber M (2011) Data Mining: Concepts and Techniques. San Francisco: Morgan Kaufmann, 744 p.

Hothorn T, Leisch F, Zeileis A (2005) The design and Analysis of benchmark experimentos. **Journal of Computational and Graphical Statistics** 14(3):675–699.

Jin FF (1997) An equatorial ocean recharge paradigm for ENSO. Part I: Conceptual model. **J Atmos Sci** 54:811-829.

Kao H-Y, J-Y Yu (2009) Contrasting eastern-Pacific and central-Pacific types of ENSO, **J. Clim.** 22(3):615–632.

Kirtman BP, Schopf OS (1998) Decadal variability in ENSO predictability and prediction. **J Clim** 11:2804-2822.

Ludescher J, Gozolchiani A, Bogachev MI, Bunde A, Havlin S, Schellnhuber HJ (2014) Very early warning of next El Niño. **Proceedings of the National Academy of Sciences** 111(6):2064-2066.

Luo JJ, Masson S, Behera SK, Yamagata T (2008) Extended ENSO predictions using a fully coupled ocean–atmosphere model. **Journal of Climate** 21(1):84-93.

McPhaden MJ (2003) Tropical Pacific Ocean heat content variations and ENSO persistent barriers. **Geophys Res Lett** 30.

McPhaden MJ, Zebiak SE, Glantz MH (2006) ENSO as an integrating concept in earth science. **Science** 314(5806):1740-1745.

Meinen CS, McPhaden MJ (2000) Observations of warm water volume changes in the equatorial Pacific and their relationship to El Niño and La Niña. **J Clim** 13:3551-3559.

Monard MC, Baranauskas JA (2003) Indução de Regras e Árvores de Decisão. In: Rezende SO (Eds.) *Sistemas Inteligentes - fundamentos e aplicações*. Barueri: Manole Ltda. 2003. p. 115-139.

Mitchell T (1997) Decision Tree Learning. In: Mitchell T (Eds.) *Machine Learning*. The McGraw-Hill Companies. 1997. p. 52-78.

Nooteboom PD, Feng QY, Lopez C, Hernandez-García E, Dijkstra A (2018) Using network theory and machine learning to predict El Nino. **Earth Syst. Dynam.** 9:969-983.

Phillips ND, Neth H, Woike JK, Gaissmaier W (2017) FFTrees: A toolbox to create, visualize, and evaluate fast-and-frugal decision trees. **Judgment and Decision making** 12(4):344-368.

Pinault JL (2016) Anticipation of ENSO: what teach us the resonantly forced baroclinic waves. **Geophy & Astrophys Fluid Dyn** 110(6):518-528.

Quinlan JR (1993) *C4.5: programs for machine learning*. San Francisco: Morgan Kaufmann.

Ronghui H, Yifang W (1989) The influence of ENSO on the summer climate change in China and its mechanism. **Advances in Atmospheric Sciences** 6(1):21-32.

Silva TM, Hornberger GM (2019) Identifying El Niño-Southern Oscillation influences on rainfall with classification models: Implications for water resource management of Sri Lanka. **Hydrology and Earth System Sciences** 23(4):1905-1929.

Souza Júnior JA, Nechet D, Oliveira, MCF, Albuquerque MF (2009) Estudo do comportamento da temperatura e precipitação nos períodos chuvosos e menos chuvosos em Belém-PA em anos de fortes eventos de El Niño e La Niña. **Revista Brasileira de Climatologia** 5:87-101.

Stojanovic M, Apostolovic M, Stojanovic D, Milošević Z, Toplaovic A, Lakušić VM, Golubovic M (2014) Understanding sensitivity, specificity and predictive values. **Vojnosanit Pregl** 71(11):1062–1065.

Tang Y, Zhang RH, Liu T (2018) Progress in ENSO prediction and predictability study. **Natl Sci Rev.** 5:826-839.

Teli A, Amith A, Bhanu Kaushik K, Gopala Krishna Vasanth K, Sowmya BJ, Seema S (2020) Efficient decision support system on agrometeorological data. **Advances in Intelligent Systems and Computing** 940:875-890.

Trenberth KE (1997) The definition of El Niño. **Bull Amer Met Soc** 78:2771-2777.

Wei W, Yan Z, Jones PD (2019) A decision-tree approach to seasonal prediction of extreme precipitation in eastern China. **International Journal of Climatology** (in press).

Witten IH, Frank E (2005) Data Mining: Practical Machine Learning Tools and Techniques, San Francisco: Morgan Kaufmann.

Zhang M-N, Liu J, Mao K-X, Li Y, Zhang X-H, Shi Y-J (2006) The general distribution characteristics of thermocline of China Sea. **Marine Forecasts** 23(4):51–58.

Zhu X, Xu Q, Tang M, Li H, Liu F (2018) A hybrid machine learning and computing model for forecasting displacement of multifactor-induced landslides. **Neural Comput. Appl.** 30(12):3825-3835.

CAPÍTULO 3 - Influence of El Niño and La Niña on coffee yield in the main coffee-producing regions of Brazil¹

ABSTRACT - Coffee is the most consumed beverage and one of the most valuable commodities worldwide. The crop is very sensitive to meteorological elements, mainly at the microclimatic scale, such as solar radiation, air temperature, and precipitation. El Niño and La Niña are atmospheric phenomena characterized by temperature anomalies in tropical areas of the Pacific Ocean, and changing wind and precipitation patterns in tropical and mid-latitude regions. For these reasons, the objective of this study was to evaluate the influence of El Niño and La Niña on *Coffea arabica* and *canephora* yields in the states and localities of the main Brazilian coffee-producing regions. We considered the states of Minas Gerais, São Paulo, Paraná, Bahia, Espírito Santo, and Rondônia. The yield data were obtained from 79 localities for the period 2002–2017 from the Brazilian Institute of Geography. Daily mean air temperature and precipitation were obtained from the NASA-POWER platform and the quarterly registry of the value of the ONI (Oceanic Niño Index) index was obtained from the National Oceanic and Atmospheric Administration. El Niño tended to decrease precipitation, and increase temperature and water deficits for all Brazilian coffee regions. Neutral and La Niña years were climatically similar. Climatic elements tended to be less variable and favor high coffee yields during El Niño years at national, regional, and local scales. The yield increase occurred because the hottest days of EN happen in the first quarter of the phenological cycle, when the crop is normally in the vegetative phase, favoring the generation of new branches. The highest historical yields were generally correlated with the occurrence of El Niño.

Keywords: applied climatology, climate changes, *Coffea* sp., ENSO

3.1 Introduction

Coffee is a perennial plant adapted to tropical climates, belonging to the Rubiaceae family, which includes several species. *Coffea arabica* and *C. canephora* (Robusta) are the most economically important, accounting for 70 and 30% of world coffee production, respectively (Fraser et al. 2014). Coffee is one of the most popular beverages worldwide, and the latest coffee trade statistics (2016/2017) estimated that world exports totaled about 10.2 billion kg. Brazil is the largest producer and the third

¹Este capítulo corresponde ao artigo científico publicado na revista Theoretical and Applied Climatology (2019) doi:10.1007/s00704-019-03039-9

largest consumer, with exports of about 3.7 billion kg in the year 2018 (International Coffee Organization 2019).

Coffee crop is very sensitive to meteorological elements (Aparecido et al. 2014), such as solar radiation, precipitation, and air temperature (Hoogenboom 2000). Craparo et al. (2015) reported that not only coffee production but also coffee quality were highly sensitive to climatic elements changes. Therefore, coffee production is limited to the intertropical zone, from 20–25°N in Hawaii to 24°S in Brazil, mainly due to factors associated with temperature and humidity (Smith 1989). The ideal temperature range for growing arabica coffee is between 19 and 22 °C (Camargo and Camargo 2001). Higher temperatures not only promote flower buds formation and stimulate fruit growth, but also increase pests and disease occurrence that can compromise the drink quality, whereas very low temperatures also negatively affect the coffee, which cannot tolerate cold (DaMatta and Ramalho 2006). Coffee is very susceptible to frost, temperatures < 10 °C can inhibit plant growth, and temperatures of – 2 °C near the leaves may damage the tissues. In most coffee-producing countries, water deficits are more frequent than frosts, so water deficits are considered the main environmental stress affecting production (DaMatta and Ramalho 2006). Water stress in coffee plants after fertilization also impairs fruit growth (Camargo 2010).

Another physiological and complex peculiarity of coffee crops is that even under adequate cropping conditions, production is often irregular and follows a biennial pattern (DaMatta 2004). This biennial pattern, also known as bienniality, is the occurrence of high and low coffee yields in alternate years, which is commonly attributed to the restriction of photoassimilates produced by the plants (Aparecido and Rolim 2018; Rena and Maestri 1986). Therefore, in high-yielding years, the production of photoassimilates is allocated for fruit formation and growth, and in low-yielding years, photoassimilates are allocated for vegetative growth, with little generation of productive branches (Rodrigues et al. 2013; Silva et al. 2008).

The El Niño Southern Oscillation (ENSO) is an atmospheric phenomenon characterized by temperature anomalies in tropical areas of the Pacific Ocean, e.g., changing wind and precipitation patterns in tropical and mid-latitudinal regions (Souza Júnior et al. 2009). ENSO has two distinct phases: El Niño, a hot phase, and La Niña, a cold phase (Berlato et al. 2005). The period of the cycle in which neither El Niño nor

La Niña occur is classified as neutral phase, which presents intermediate weather conditions, adopted as standard.

The El Niño phase is caused by an abnormal warming of the Pacific Ocean, which, generally, increases precipitation. The La Niña phase is due to a cooling of the Pacific Ocean, generating an opposite effect to El Niño, i.e., decreases the average precipitation (Grimm et al. 2000). These two phases can both positively and negatively affect the productive performance of agricultural species, and Alves et al. (1997) have reported that ENSO greatly influences the climate of Brazil, with precipitation one of the most strongly modified climatic elements, increasing or decreasing precipitation.

We assume that the atmospheric phenomena of El Niño and La Niña directly influence coffee yield. Although there are studies on crops such as soybean, maize, and bean for Brazil (Júnior and Sentelhas 2019; Cirino et al. 2015), the same is not true for coffee, a crop of significant economic value to the country. In addition, understanding the consequences of ENSO for different regions of the world is important to understanding the underlying mechanism of this phenomenon and thus improving its prediction ability. Therefore, the objective of this study was thus to investigate the influence of El Niño and La Niña for 2002–2017 in the national, main coffee-producing states and localities in Brazil.

3.2 Data and methodology

We obtained the historical series (2002-2017) of average coffee yield from the Brazilian Institute of Geography (IBGE 2018). The study sites were the main states in Brazil producing arabica coffee: Minas Gerais (MG), São Paulo (SP), Paraná (PR), and Bahia (BA), and the main states producing robusta coffee: Espírito Santo (ES) and Rondônia (RO) (Conab 2019). We removed the temporal series tendency of each state to facilitate the association between the occurrence of El Niño and La Niña and their influence on yield. The technological tendency of each locality was determined by a simple linear regression analysis, with the years as the independent variable (X_i) in the original yield series (Y_i). The technological tendency was removed from the original series to produce a corrected series, $Y_{ci} = Y_i - (Y_{xi} - Y_0)$. Where Y_{ci} is the yield of year without technological trend, Y_i is the original yield of year i , Y_{xi} is the yield of year i

estimated by regression and Y_0 is the yield of the last year of the historical series (Cunha et al. 2001). The variations in yield could therefore be attributed to climatic effects (Cunha et al. 2001; Carmona and Berlato 2002; Praela et al. 2005).

Climatic data such as maximum, minimum and average air temperature ($^{\circ}\text{C day}^{-1}$) and precipitation (mm day^{-1}) were obtained from the NASA-POWER platform. The Earth Sciences research program of NASA provided data for long-term climatological estimates of meteorological elements and surface solar fluxes. These data are based on models and satellite information that are sufficiently accurate to provide reliable data from solar and meteorological measurements for regions where surface measurements are scarce or nonexistent. The meteorological elements were based on the MERRA-2 assimilation model and are available as climatological and interannual means and daily time series. All elements were available for $0.5 \times 0.5^{\circ}$ grids (Stackhouse et al. 2018).

The NASA data have been previously used and evaluated, such as modeling wheat phenology in the USA (White et al. 2008), simulating maize production in China (Bai et al. 2010), predicting fires in Serbia (Westberg et al. 2010) and simulating water requirements for maize in the province of Free State in South Africa (Moeletsi and Walker 2012). McPhee and Margulis (2005) and White et al. (2008) verified the accuracy of the NASA systems to estimate precipitation and air temperature, respectively, in the USA, demonstrating that the NASA POWER data for air temperature agreed well with data from meteorological stations.

Actual evapotranspiration (AET) (mm month^{-1}), soil-water deficit (DEF) (mm month^{-1}) and soil-water surplus (SUR) (mm month^{-1}) were estimated by the sequential water-balance model developed by Thornthwaite and Mather (1955) (Eqs. 1, 2, 3, 4, 5, 6 and 7) using an available soil-water capacity of 100 mm, because this value represents most of the soils in Brazilian coffee regions as reported by Meireles et al. (2009). Monthly potential evapotranspiration (PET) was calculated using the Camargo model (1971) (Eq. 8)

$$DEF = PET - AET \quad (1)$$

$$SUR = 0 \quad \text{if } STO < CAD \quad (2)$$

$$SUR = (P - PET) - ALT \quad \text{if } STO = CAD \quad (3)$$

$$AET = P + |ALT| \quad \text{if } ALT < 0 \quad (4)$$

$$AET = PET \quad \text{if } ALT \geq 0 \quad (5)$$

$$ALT = \Delta STO \quad (6)$$

$$NAC = CAD \ln \left(\frac{ARM}{CAD} \right) \quad (7)$$

$$PET = 0.01 \left(\frac{Q_0}{2.45} \right) T NDP \quad (8)$$

where P is precipitation (mm), STO is the current soil-water storage (mm), ALT is change in STO (mm), NAC is the drying potential of the soil (mm), CAD is available soil-water capacity (mm), Q_0 is solar irradiance at the top of the atmosphere ($\text{MJ m}^{-2} \text{day}^{-1}$), T is average air temperature of the period ($^{\circ}\text{C}$) and NDP is the number of days in the period.

We utilized data from the Oceanic Niño Index (ONI) for the El Niño (EN), La Niña (LN) and the neutral years (NE) of the 2002-2017 ENSO cycles (Fig. 1), provided by the National Oceanic and Atmospheric Administration (NOAA). The ONI is NOAA's primary indicator for monitoring EN and LN. It tracks the running 3-month average Sea Surface Temperatures (SST) in the east-central tropical Pacific between 120° - 170°W . Scientists call the area the Niño 3.4 region. NOAA considers EN conditions to be present when the ONI is +0.5 or higher, indicating the east-central tropical Pacific is significantly warmer than usual. LN conditions exist when the Oceanic Niño Index is -0.5 or lower, indicating the region is cooler than usual (Climate Prediction Center 2012). ENs in the tropical Pacific Ocean are detected by various methods, including satellite remote sensing, sea-level analyses and anchored, floating and disposable buoys. Many of these systems have been part of the Tropical Ocean Global Atmosphere program and are now being developed into an ENSO operational system of observation (Climate Prediction Center 2012). We used 2 EN, 3 LN and 9 NE years, which determined using ONI index oscillations for each year of the study. Years when mean ONI was >0.5 , <-0.5 and $-0.5 < x < 0.5$ were classified as ENs, LNs and NEs, respectively.




Fig. 1 Oceanic Niño Index (ONI) measured for the El Niño-Southern Oscillation. El Niño (red) and La Niña (blue) periods based on a threshold of $\pm 0.5^\circ\text{C}$ for the ONI. The vertical error bars means standard deviation of ONI (ENSO index) by year.

The difference in the yields and in the elements climatic (T, P, STO, PET, AET, DEF and SUR) for the EN, LN and NE years were analyzed by box-plot charts and its mean compared with Tukey test at 0.05 probability. We studied the influence of components of the water balance on crop yield using principal component analyses (PCAs) for retaining, in order of estimation, the maximum information for the total variation in the data. PCAs reduce the amount of data, with the lowest possible information loss. We analyzed the influences of ENs, LNs, and NEs on coffee yield by radar graphs using average yields for each phenomenon (EN, LN, and NE) by identifying correlations between yield and the water-balance components for each phenomenon. Maps and graphs were generated for each phenomenon using inverse-distance weighting for interpolating yield, to demonstrate the different effects of ENSO phases for each of the study sites.

3.3 Results and discussion

The ENSO signal affects Brazilian coffee yields differently at national, regional, and local levels. At the national level, the EN years decreased the absolute values of yields (outliers) by up to 1000 kg ha^{-1} , although it does not affect the mean values (Fig. 2). Bastianin et al. (2018) also stated that the impact of ENSO in large areas of coffee plantations could be considered small, accounting for only 2.2% of short-term coffee fluctuations but accounting for 8.3% of long-term fluctuations. Evaluating the impact of

ENSO on coffee yields at regional or even smaller scales is therefore necessary. Chimeli et al. (2008) investigated the effects of anomalies of SST on Brazilian maize yields and prices, reporting a negative correlation between ENSO and maize production, and a positive correlation between ENSO and maize prices.




Fig. 2 Yield (kg ha^{-1}) in the El Niño, La Niña, and neutral year events of the significant regions of coffee production in Brazil, from 2002 to 2017. Legend: (— internal) represents the second quartile or median; ($\square$) the first and third quartiles; (T e L) third and first quartiles up to the upper and lower limits; ($\bullet$) values of the averages; ($\ast$) maximum and minimum values; (-) outliers values. Means followed by the same letter do not differ among themselves by the Tukey test at 5% significance.

Although the number of events related to the ENSO signal has the disadvantage of presenting different frequencies, several other authors have also relied on similar data to explore the influence of ENSO on yield (Júnior and Sentelhas 2019; Li et al. 2019) and the prediction of these weather phenomena (Chen et al. 2004; Barnston et al. 2012; Pinault 2016). Moreover, most existing studies on the impact of these phenomena on agriculture are based on simulated and unobserved yield data (e.g., Phillips et al. 1998, 1999; Adams et al. 2003). Although simulated observations offer some benefits, such as availability over a longer period, their main disadvantage is that these data largely ignore any adaptive actions that producers may have taken in response to or in anticipation of climate shocks (Miao et al. 2016).

We verified that the effects of EN, LN, and NE were more evident on a regional scale because, according to Tukey's analysis ($p < 0.05$), these phenomena directly

affect regional meteorological conditions. The EN years differed from NE and LN years, which fall into the same group for most climatic elements. For the EN years, there was an increase in the air temperature by 2.99%, with a high in DEF (74%) and PET (2.85%), in relation to NE years (Fig. 3).

The main components of the PCA explained 73.50% of the system variance, indicating positive correlations of yield with air temperature, precipitation, PET, and AET and negative correlations with DEF, soil-water surplus (SUR), and STO (Fig. 4). These factors can stimulate the growth and flowering of coffee trees, with a positive impact on yield (Café de Colombia 2014). Poveda et al. (2001) reported similar results for the coffee zones of Colombia, but Bastianin et al. (2018) suggested that this increase was temporary, although it occurred at a consistent frequency.

Precipitation ($< 0.37\%$) and STO ($< 5.69\%$) slight decreased during LNs, but air temperature ($< 0.94\%$) also decreased, increasing SUR ($> 9.78\%$). Therefore, when compared with EN years, LN years have higher precipitation and lower temperature. These results corroborate the findings of Cirino et al. (2015), who observed lower precipitation and higher temperatures during the EN years and the opposite was also observed for the LN years, mainly for the Northeast of Brazil.

The PCA for LN phenomenon explained 76.82% of the system variance, with a positive correlation between yield and STO, and negative correlations of yield with air temperature, precipitation, PET, AET, SUR, and DEF (Fig. 5). The interaction of these factors may favor increased incidence of diseases (Bastianin et al. 2018) such as coffee rust (*Hemileia vastatrix* Berkeley e Broome) (Avelino et al. 2015), which represents the greatest threat to the global coffee industry (Cressey 2013) and is most severe in Arabica coffee (Eskes 2005; Dineshes et al. 2011). These consequences also affected Colombia, where coffee production and exports decreased, which always increased coffee prices after an LN (Poveda et al. 2001).




Fig. 3 A Average monthly air temperature, B Precipitation distribution, C Potential evapotranspiration, D Actual evapotranspiration, E Soil-water storage, F Water deficit and G Water surplus at El Niño, La Niña and neutral years, from the significant regions of coffee production in Brazil, from 2002 to 2017. Legend: (— internal) represents the second quartile or median; (□) the first and third quartiles; (T and ⊥) third and first quartiles up to the upper and lower limits; (●) values of the means; (*) maximum and minimum values; (-) discrepancies (outliers). Means followed by the same letter do not differ among themselves by the Tukey test at 5% significance.

ENs are characterized by lower precipitation rates, so yield is negatively affected by the increases in air temperature, PET and, consequently, DEF (Fig. 4). Rendón et al. (2015) reported that the effect of ENSO on air temperature in Colombia was larger in some months and largest between December and March; the hottest days during ENs were during the first quarter (January–March). Coffee trees during this period are in the vegetative phase, when foliar buds form, or in the phase of bean granulation. The vegetative phase is represented by long days, with photoperiods > 13 h of effective light or > 12 h of bright solar radiation (Camargo 1985), not suffering negative influence by the characteristics presented by EN years.




Fig. 4 Principal component analysis of the coffee water balance of the main production regions in Brazil, from 2002 to 2017, for the El Niño years. Legend: Y = yield (kg ha^{-1}), and T = air temperature ($^{\circ}\text{C}$), P = precipitation (mm), DEF = water deficit (mm), SUR = water surplus (mm), PET = potential evapotranspiration (mm), AET = actual evapotranspiration (mm), STO = current soil-water storage (mm).

In the NE years yield, as well as air temperature, potential evapotranspiration and water deficit have directly proportional magnitudes. Therefore, the higher the air temperature, the higher the yield since in the NE years the water surplus is high (Fig. 5).




Fig. 5 Principal component analysis of the coffee water balance of the main production regions in Brazil, from 2002 to 2017, for the neutral years. Legend: Y = yield (kg ha^{-1}), and T = air temperature ($^{\circ}\text{C}$), P = precipitation (mm), DEF = water deficit (mm), SUR = water surplus (mm), PET = potential evapotranspiration (mm), AET = actual evapotranspiration (mm), STO = current soil-water storage (mm).

Increases in DEF and air temperature during LNs benefited yield, when SUR was large and air temperatures were low (Fig. 6). Rendón et al. (2015) demonstrated that ENSO had a generalized effect on the minimum air temperature during the first half of the year during the coldest days of LNs (January–July). PET usually decreases substantially in the fruit-maturation stage, and moderate DEFs benefit the quality of the product (Camargo and Camargo 2001), in contrast to the conditions for LNs, which can decrease coffee yield.




Fig. 6 Principal component analysis of the coffee water balance of the main production regions in Brazil, from 2002 to 2017, for the La Niña years. Legend: Y = yield (kg ha^{-1}), and T = air temperature ($^{\circ}\text{C}$), P = precipitation (mm), DEF = water deficit (mm), SUR = water surplus (mm), PET = potential evapotranspiration (mm), AET = actual evapotranspiration (mm), STO = current soil-water storage (mm).

These relationships between water-balance components and anomalies of SST can affect the scenarios analyzed above and affect yield locally. ENs and LNs influenced coffee yield at a regional level, even though average coffee yields were similar; the ENSO phenomena affected air temperature and precipitation on regional scales during the crop cycle for both Arabica coffee (MG, SP, PR, and BA) and Robusta coffee (RO and ES) (Fig. 7). The difference in yield was not extensive in RO and PR, but the difference was noticeable in other states such as ES, where yield during LNs increased toward the south. SP was positively influenced by ENs, when yield increased significantly in the midwest, nevertheless also yield increased in Alta Mogiana to 1761–2517 kg ha^{-1} during LNs.

LN's influenced coffee yield negatively in Triângulo Mineiro but positively in northern MG (Norte de Minas), which is a drier region of the state. ENs provided better yields in southern MG (Sul de Minas), despite the higher DEFs. A monthly DEF can be positively or negatively correlated with yield, depending on the phenological phase of the coffee trees (Syvertsen and Garcia-Sanchez 2014). DEFs in years with high yields have more influence on flowering, bean formation, and yield during the phenological year (Aparecido and Rolim 2018). Monthly DEF mainly influences the phases of vegetative development and final maturation in low-yielding years. ENs were also generally beneficial in BA, especially in the extreme western (Extremo Oeste) part of the state. Yield consequently decreased from ENs to LNs and NEs throughout the state, especially along the coast (Fig. 8).




Fig. 7 Yield (kg ha^{-1}) for the main coffee-producing states in Brazil in the events **A** El Niño, **B** La Niña and **C** neutral years, from 2002 to 2017. Legend: * is the Robusta coffee (*Coffea canephora*).

The extreme western (Extremo Oeste) region of BA is more productive than the southern center (Centro Sul) region, with higher yields during ENs followed by NEs. LNs were detrimental to yield in this region. While to BA, the LN years had a low yield, the same was not observed for the northwest (Noroeste) of ES, especially near the cities of Boa Esperança, Marilândia, Vila Valério, and São Gabriel da Palha. The Jequitinhonha Valley (Vale do Jequitinhonha) and Zona da Mata had the lowest yields in MG, oscillating between the ENSO events. Much of southern MG (Sul de Minas) was positively affected by ENs and LNs, which provided larger SURs, favoring disease occurrence. The highest yields in MG during NEs were in Alto Paranaíba and Triângulo Mineiro. Yields in PR and RO were slightly higher during ENs. Yields in SP during ENs were lowest in the midwest but increased in Alta and Baixa Mogiana.

Cirino et al. (2015), studying the effects of ENSO on yield, found that crops such as maize and beans are quite vulnerable to the effects of these phenomena in northern Brazil, and can reduce their yields by up to 50% in EN years, while the LN years are substantially harmful for bean crop in the same region. In the southern region of the country, as in this study, the LN years are harmful to crops such as maize and sugarcane. In addition, Ubilava and Abdolrahimi (2019) found that SST anomalies are conditional on the countries' income and, for maize crop, the EN phenomenon is detrimental in lower income countries.




Fig. 8 Local Yields (kg ha^{-1}) for the states of: **A** Bahia, **B** Espírito Santo, **C** Minas Gerais, **D** Paraná, **E** Rondônia e **F** São Paulo, in the events of **A** El Niño, **B** La Niña and **C** neutral years, from 2002 to 2017.

There were a direct correlation between precipitation in South Center (Centro Sul) BA and ENs and LNs (Table 1), and SURs were associated with 88% of the NEs. BA have the lowest altitude compared with the other coffee-producing states in Brazil. There was a correlation of 93% between altitude and LNs in the extreme western (Extremo Oeste) part of BA, and STO was correlated with ENs and NEs, and as previously stated, high STOs during NEs can be harmful.

Table 1 Linear correlation between the air temperature (T), precipitation (P), water deficit (DEF), water surplus (SUR), soil-water storage (STO), altitude and El Niño (EN) phenomenon, neutral (NE) years and La Niña (LN) phenomenon for the state of Bahia.

	Bahia					
	Centro Sul			Extremo Oeste		
	EN	NE	LN	EN	NE	LN
T	0.26	0.44	0.18	0.83	0.80	0.68
P	0.89	0.78	0.92	0.95	0.94	0.77
DEF	-0.63	-0.46	-0.69	-0.59	-0.64	-0.61
SUR	0.77	0.88	0.72	0.94	0.88	0.60
STO	0.72	0.57	0.77	0.96	0.95	0.79
Altitude	0.42	0.59	0.35	-0.89	-0.89	-0.93

DEF was the water-balance component that correlated most with ENs, NEs, and LNs in Central ES, for 48, 78, and 75% of the cases, respectively (Table 2). This finding accounted for the increased yield during ENs, when DEF decreased. Altitude in northwestern (Noroeste) ES accounted for the highest percentage of cases for all events. Several studies, such as Figueroa et al. (2000), Serrano and Castrillón (2002), and Decasy et al. (2003) have reported that altitude is also an important factor for coffee quality.

Table 2 Linear correlation between the air temperature (T), precipitation (P), water deficit (DEF), water surplus (SUR), soil-water storage (STO), altitude and El Niño (EN) phenomenon, neutral (NE) years and La Niña (LN) phenomenon for the state of Espírito Santo.

	Espírito Santo					
	Central			Noroeste		
	EN	NE	LN	EN	NE	LN
T	0.12	0.53	0.44	0.05	0.33	0.11
P	-0.46	-0.77	-0.73	-0.05	-0.33	-0.11
DEF	0.48	0.78	0.75	0.05	0.33	0.11
SUR	-0.33	-0.70	-0.63	-0.05	-0.33	-0.11
STO	-0.40	-0.75	-0.68	-0.04	-0.33	-0.11
Altitude	-0.08	-0.31	-0.16	0.33	0.55	0.62

Altitude in MG was most correlated with ENs, NEs, and LNs in southern MG (Sul de Minas) and Zona da Mata (Table 3). Nevertheless, MG regions present the highest altitudes, their coffee is ranked as the best quality (Silva et al. 2008). DEF was strongly correlated with LNs and NEs in Triângulo Mineiro and Alto Paranaíba, and air

temperature was correlated with 17% of the ENs. Most components of the water balance were correlated with ENSO in the Jequitinhonha Valley (Vale do Jequitinhonha) and northern (Norte) MG, with altitude in 93% of the ENs, with air temperature, precipitation, SUR, and STO in 92% of the NEs, and with all components except altitude in 99% of the LNs.

Table 3 Linear correlation between the air temperature (T), precipitation (P), water deficit (DEF), water surplus (SUR), soil-water storage (STO), altitude and El Niño (EN) phenomenon, neutral years (NE) and La Niña (LN) phenomenon for the state of Minas Gerais.

	Minas Gerais											
	Sul de Minas			Triângulo Mineiro e Alto Paranaíba			Vale do Jequitinhonha e Norte			Zona da Mata		
	EN	NE	LN	EN	NE	LN	EN	NE	LN	EN	NE	LN
T	0.45	0.55	0.36	0.17	0.23	0.25	-0.81	-0.92	-0.99	-0.34	0.04	0.08
P	0.48	0.42	0.37	0.15	-0.27	-0.26	0.81	0.92	0.99	-0.34	0.04	0.08
DEF	0.34	0.47	0.28	0.08	0.38	0.39	-0.79	-0.91	-0.99	-0.26	-0.10	0.01
SUR	0.37	0.24	0.27	0.10	-0.33	-0.33	0.81	0.92	0.99	0.35	-0.01	-0.05
STO	-0.28	-0.42	-0.23	0.03	-0.30	-0.30	0.80	0.92	0.99	0.31	0.02	-0.06
Altitude												
e	0.70	0.56	0.50	0.03	0.02	-0.31	0.93	0.81	0.57	0.41	0.71	0.83

Altitude was also the most correlated component with the ENSO signal for Paraná (PR). For Rondônia (RO), in addition to altitude, air temperature also correlates with ENSO, possibly because this region has high air temperature patterns due to the influence of continentality in this region (Table 4). These results indicate the influence of latitude and continentality on ENSO and, consequently, on yield. According to Li et al. (2019), yields are actually more sensitive to ENSO at high latitudes, affecting several crops, such as rice. The El Niño phenomenon in Brazil caused opposite effects to La Niña, favoring soybean and maize yield at high latitudes, and reducing it at low latitudes (Júnior and Sentelhas 2019).

Table 4 Linear correlation between the air temperature (T), precipitation (P), water deficit (DEF), water surplus (SUR), soil-water storage (STO), altitude and El Niño (EN) phenomenon, neutral years (NE) and La Niña (LN) phenomenon for the state of Paraná and Rondônia.

	Paraná				Rondônia		
	Norte Paranaense				Leste Rondoniense		
	EN	NE	LN		EN	NE	LN
T	-0.41	-0.50	-0.22	T	-0.72	-0.73	-0.77
P	-0.41	-0.50	-0.22	P	-0.55	-0.45	-0.68
DEF	-0.40	-0.46	-0.18	DEF	0.56	0.58	0.58
SUR	-0.43	-0.53	-0.25	SUR	-0.55	-0.49	-0.65
STO	0.40	0.45	0.18	STO	-0.60	-0.55	-0.69
Altitude	-0.75	-0.83	-0.36	Altitude	0.92	0.80	0.94

There were a direct correlation between air temperature and precipitation in SP with NE years in the both Alta and Baixa Mogiana (Table 5). Altitude and STO in the Alta Mogiana were correlated with EN and LN years, respectively. Air temperature, precipitation, and SUR in the BaixaMogiana correlated with EN years, and altitude was with LN years.

Table 5 Linear correlation between the air temperature (T), precipitation (P), water deficit (DEF), water surplus (SUR), soil-water storage (STO), altitude and El Niño (EN) phenomenon, neutral years (NE) and La Niña (LN) phenomenon for the state of São Paulo.

	São Paulo					
	Alta Mogiana			Baixa Mogiana		
	EN	NE	LN	EN	NE	LN
T	-0.29	-0.07	0.67	-0.94	-0.58	-0.61
P	-0.29	-0.07	0.67	0.94	0.58	0.61
DEF	-0.27	-0.04	0.69	-0.93	-0.48	-0.62
SUR	-0.29	-0.07	0.67	0.94	0.52	0.62
STO	0.26	0.02	-0.70	0.93	0.50	0.62
Altitude	-0.40	0.06	-0.36	-0.21	0.57	-0.63

3.4 Conclusion

We present results that support the conclusion that the air temperature, precipitation, potential evapotranspiration (PET), soil water storage (STO), water

deficits (DEF) and water surplus (SUR) correlate with the ENSO signal and cause an important variation in coffee yield in all production regions in Brazil.

Conditions during the El Niño (EN) years decrease precipitation and increase the air temperature, resulting in a higher DEF and PET compared to the neutral (NE) and La Niña (LN) years. The opposite happens in the LNs years, there is an increase in precipitation and STO, resulting in higher SUR. NEs years show similar patterns to LNs years.

The average coffee yield values in ENs, LNs and NEs years in Brazilian national level are not statistically different, but the standard deviation of yield in years of ENs is lower compared to the LNs and NEs years. Nevertheless, there are significant differences between coffee-producing regions against the ENSO phenomenon.

Bahia is the state most affected by ENSO. The ENs years condition increase yield reaching 2439.64 kg ha⁻¹ and the LNs years decrease yield to 325.96 kg ha⁻¹. The states of Paraná and Rondônia are the less affected by ENSO, with average yields around 2000 and 1000 kg ha⁻¹, respectively.

Minas Gerais, the largest coffee producer state in Brazil, has its average yield reduced to 772 kg ha⁻¹ in the LNs years. In the EN and NE years average yields of 1638.74 and 1368.24 kg ha⁻¹ occur, respectively. Vale do Jequitinhonha is the region that most suffers from the yield decrease in LN years, with an average yield of 1036.94 kg ha⁻¹, followed by the Zona da Mata region. EN years favor yield in the southern Minas Gerais region, while NE years favor the Triângulo Mineiro and Alto Paranaíba.

Even though the present study shows the influence of Enso in short time series, it was possible to verify how much this phenomenon affects the different regions of Brazil. In addition, the results presented here may provide support for further studies, even with the simulation of some data.

3.5 References

- Adams RM, Houston LL, McCarl BA, Mario Tiscareño LM, Matus GJ, Weiher RF (2003) The benefits to Mexican agriculture of an El Niño-Southern Oscillation (ENSO) early warning system. *Agricultural and Forest Meteorology* 115:183–194
- Alves MB, Souza EB, Repelli CA, Vitorino MI, Ferreira NS (1997) Episódios de La Niña na bacia do oceano pacífico e equatorial e a distribuição sazonal e intra-sazonal das chuvas no setor norte do nordeste brasileiro. *Revista Brasileira de Meteorologia* 12(1):63–76
- Aparecido LEO, Rolim GS (2018) Forecasting of the annual yield of Arabic coffee using water deficiency. *Pesq Agrop Brasileira* 53(12):1299–1310
- Aparecido LEO, Rolim GS, Souza PS (2014) Flowering and harvest ing periods of macadamia-walnut for areas of the southeastern coffee region. *Rev Bras Frutic* 36:165–173
- Avelino J, Cristancho M, Georgiou S, Imbach P, Aguilar L, Bornemann G, Läderach P, Anzueto F, Hruska AJ, Morales C (2015) The coffee rust crises in Colombia and Central America (2008–2013): Impacts, plausible causes and proposed solutions. *Food Security* 7(2):303–321
- Bai J, Chen X, Dobermmman A, Yang H, Cassman KG, Zhang F (2010) Evaluation of NASA satellite- and model-derived weather data for simulation of maize yield potential in China. *Agron J* 102(1):9–16
- Barnston AG, Tippet MK, L'Heureux ML, Li S, DeWitt DG (2012) Skill of real-time seasonal ENSO model predictions during 2002–11: is our capability increasing? *Bull Am Meteorol Soc* 93(5):631–651
- Bastianin A, Lanza A, Manera M (2018) Economic impacts of El Niño southern oscillation: evidence from the Colombian coffee market. *Agric Econ* 1:3–17
- Berlato MA, Farenzena H, Fontana DC (2005) Associação entre El Niño Oscilação Sul e a produtividade do milho no Estado do Rio Grande do Sul. *Pesq Agrop Brasileira* 40(5):423–432
- Café de Colombia (2014) Our coffee regions. Retrieved from: <<http://www.cafedecolombia.com>>
- Camargo AP (1971) Balanço hídrico no Estado de São Paulo. 3.ed. Campinas: Instituto Agronômico. 24p. (Boletim, 116)
- Camargo AP (1985) Florescimento e frutificação de café arábica nas diferentes regiões cafeeiras do Brasil. *Pesq Agrop Brasileira* 20(7):831–839

Camargo MBP (2010) The impact of climatic variability and climate change on arabic coffee crop in Brazil. *Bragantia*. 69:239–247

Camargo AP, Camargo MBP (2001) Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil. *Bragantia*. 60(1):65–68

Carmona LC, Berlato MA (2002) El Niño e La Niña e a produtividade do arroz irrigado no Estado do Rio Grande do Sul. *Revista Brasileira de Agrometeorologia*. 10(1):147–152

Chen D, Cane MA, Kaplan A, Zebiak SE, Huang D (2004) Predictability of El Niño over the past 148 years. *Nature*. 428(6984):733–736

Chimeli A, Souza Filho F, Holanda M, Petterini F (2008) Forecasting the impacts of climate variability: lessons from the rainfed corn market in Ceará. *Brazil Environment and Development Economics* 13(2):201–227

Cirino PH, Féres JG, Braga MJ, Reis E (2015) Assessing the Impacts of ENSO-related weather effects on the Brazilian Agriculture. *Procedia Economics and Finance* 24:146–155

Climate Prediction Center – CPC (2012) Frequently asked questions about El Niño and La Niña. Retrieved from:<https://www.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ensofaq.shtml#forecasts>

Companhia Nacional de Abastecimento – CONAB (2019) Acompanhamento da safra brasileira de café. 6(1)

Craparo ACW, Van Asten PJA, Läderach P, Jassogne LTP, Grab SW (2015) Coffea arabica yields decline in Tanzania due to climate change: global implications. *Agric For Meteorol* 207:1–10

Cressey D (2013) Coffee rust regains foothold. *Nature*. 493-587

Cunha DR, Dalmargo GN, Estefanel D, Pasinato A, Moreira MB (2001) El Niño-Oscilação Sul e seus impactos sobre a cultura da cevada no Brasil. *Revista Brasileira de Agrometeorologia* 9(1):137–1345

Damatta FM (2004) Ecophysiological constraints on the production of shaded and unshaded coffee: a review. *Field Crop Res* 86:99–114

Damatta FM, Ramalho JDC (2006) Impacts of drought and temperature stress on coffee physiology and production: a review. *Braz J Plant Physiol* 18(1):55–81

Decasy F, Avelino J, Guyot B, Perriot JJ, Pineda C, Cilas C (2003) Qualidade de diferentes cafés hondurenhos em relação a diferentes meio ambientes. *J Food Sci* 68(7):2356–2361

Dineshes KP, Shivanna P, Santa Ram A (2011) Identification of RAPD (random amplified polymorphic DNA) markers for Ethiopian wild *Coffea arabica* L genetic resources in the tropics. *Institute of Integrative Omics and Applied Biotechnology Journal* 2(4):1–7

Eskes A (2005) Phenotypic expression of resistance to coffee leaf rust and its possible relationship with durability. In: *Durable Resistance to Coffee Leaf Rust*. Viçosa-MG. Universidade Federal de Viçosa, 305-331

Figuerola P, Jimenez OH, López de LE, Anzueto F (2000) Influencia de la variedad y la altitud en las características organolépticas y físicas del café. In: *Simpósio Latinoamericano De Cafeicultura*, 19., 2000, San José, Costa Rica. Memoria... San José: ICAFE. 493-497

Fraser J, Fisher E, Arce A (2014) Reframing ‘crisis’ in fair trade coffee production: trajectories of agrarian change in Nicaragua. *J Agrar Chang* 14(1):52–73

Grimm AM, Barros VR, Doyle ME (2000) Climate Variability in Southern South America associated with El Niño and La Niña events. *J Clim* 13(1):35–57

Hoogenboom G (2000) Contribution of agrometeorology to the simulation of crop production and its applications. *Agric For Meteorol* 103(1/2):137–157

Instituto Brasileiro de Geografia e Estatística – IBGE. (2018). Sidra: Banco de Tabelas Estatísticas. Retrieved from: <<https://sidra.ibge.gov.br>>

International Coffee Organization – ICO (2019). Coffee trade statistics. Retrieved from: <<http://www.ico.org>>

Júnior RDSN, Sentelhas PC (2019) Soybean-maize off-season double crop system in Brazil as affected by El Niño Southern Oscillation phases. *Agric Syst* 173:254–267

Li Y, Yi F, Wang Y, Gudaj R (2019) The Value of El Niño-Southern oscillation forecasts to China’s agriculture. *Sustainability*. 11(15):4184

Mcphee J, Margulis SA (2005) Validation and error characterization of the GPCP-1DD precipitation product over the contiguous United States. *J Hydrometeorol* 6:441–459

Meireles E JL, Camargo MBP, Pezzopane JRM, Thomaziello RA, Fahl JI, Bardin L, Santos JCF, Japiassú LB, Garcia AWR, Miguel AE, Ferreira RA (2009) Fenologia do cafeeiro: condições agrometeorológicas e balanço hídrico do ano agrícola 2004-2005. Brasília: Embrapa Café; MAPA 5:130

Miao R, Khanna M, Huang H (2016) Responsiveness of crop yield and acreage to prices and climate. *American Journal of Agricultural Economics* 98:191–211

Moeletsi ME, Walker S (2012) Evaluation of NASA satellite and modelled temperature data for simulating maize water requirement satisfaction index in the Free State Province of South Africa. *Physics and Chemistry of the Earth, Parts A/B/C* 50-52:157–164

Phillips J, Cane M, Rosenzweig C (1998) ENSO, Seasonal rainfall patterns and simulated maize yield variability in Zimbabwe *Agricultural and Forest Meteorology* 90:39–50

Phillips J, Rajagopalan B, Cane M, Rosenzweig C (1999) The role of ENSO in determining climate and maize yield variability in the US cornbelt. *International Journal of Climatology* 19:877–888

Pinault JL (2016) Anticipation of ENSO: What teach us the resonantly forced baroclinic waves. *Geophysical & Astrophysical Fluid Dynamics* 110(6):518–528

Poveda G, Jaramillo A, Gil MM, Quiceno N, Mantilla RI (2001) Seasonally in ENSO-related precipitation, river discharges, soil moisture, and vegetation index in Colombia. *Water Resour Res* 37(8):2169–2178

Prela AP, Pereira AR, Caramori PH (2005) Influência dos fenômenos El Niño/La Niña na produtividade de trigo no estado do Paraná. *Revista Brasileira de Agrometeorologia*. 13(3):341–342

Rena AB, Maestri M (1986) Coffee Physiology. In: A.B. Rena et al. (guest eds) *Cultura do cafeeiro: fatores que afetam a produtividade*. Piracicaba, SP: POTAFOS. pp. 447

Rendón EPD, Builes VHR, Quiñones AJP (2015) Variabilidad espacial y temporal de la temperatura del aire en la zona cafetera colombiana. *Investigaciones Geográficas. Boletín* 89

Rodrigues WN, Tomaz MA, Ferrão RG, Ferrão MAG, Fonseca AFA (2013) Crop yield bienniality in groups of genotypes of conilon coffee. *Afr J Agric Res* 8:4422–4426

Serrano CEB, Castrillón JJC (2002) Influência de la latitude en la calidad de la bebida de muestras del café procedente del ecotopo 206 B en Colombia. *Cenicafé*. 53(2):119–131

Silva CA, Teodoro REF, Melo B (2008) Produtividade e rendimento do cafeeiro submetido a lâminas de irrigação. *Pesq Agrop Brasileira* 43:387–394

Smith AW (1989) Introduction. In: Clarke RJ, Macrae R (eds), *Coffee – Chemistry*. 1:1-41

Souza Júnior JA, Nechet D, Oliveira MCF, Albuquerque MF (2009) Estudo do comportamento da temperatura e precipitação nos períodos chuvosos e menos chuvosos em Belém-PA em anos de fortes eventos de El Niño e La Niña. *Revista Brasileira de Climatologia* 5:87–101

Stackhouse PW, Zhang T, Westberg D, Barnett AJ, Bristow T, Macpherson B, Hoell JM (2018) Power release 8.0.1 (with GIS applications) methodology (Data parameters, sources & validation). Retrieved from <https://power.larc.nasa.gov/documents/POWER_Data_v9_methodology.pdf>

Syvertsen JP, Garcia-Sanchez F (2014) Multiple abiotic stresses occurring with salinity stress in citrus. *Environ Exp Bot* 103:128–137

Thornthwaite CW, Mather JR (1955) The water balance. Centerton: Drexel Institute of Technology. *Climatology* 8(1):104

Ubilava D, Abdolrahimi M (2019) The El Niño impact on maize yields is amplified in lower income teleconnected countries. *Environ Res Lett* 14(5):054008

Westberg D, Soja A, Stackhouse JRPW (2010) Linking satellite-derived fire counts to satellite-derived weather data in fire prediction models to forecast extreme fires in Siberia. *Geophys Res Abstr* 12:2010–5597

White JF, Hoogenboom G, Stackhouse JRPW, Hoell JM (2008) Evaluation of NASA satellite- and assimilation model-derived long-term daily temperature data over the continental US. *Agric For Meteorol* 148:1574–1584

CAPÍTULO 4 – Considerações finais

O modelo para previsões de eventos de El Niño e La Niña por inteligência artificial se mostrou uma ferramenta de fácil utilização para uso no setor agrícola. Além de sua facilidade, o modelo apresentou acurácia média de 84%. A DTC apresentou uma acurácia de 91%, 92% e 83% para previsões de anos de El Niño, La Niña e anos neutros, respectivamente, no período de treinamento e 80%, 93% e 73%, respectivamente, para o período de validação. A previsão foi possível com 9 meses de antecipação, utilizando apenas dados trimestrais do Índice Niño Oceânico (ONI) dos períodos de março-abril-maio e outubro-novembro-dezembro do ano anterior e janeiro-fevereiro-março do ano corrente.

Já se tratando da influência destes fenômenos na produtividade de café, observou-se que os componentes do balanço hídrico se correlacionam com os eventos ENSO e, portanto, condicionam a variação na produtividade da cultura do café a nível regional. A Bahia é o estado mais afetado pelo ENSO, apresentando aumento de produtividade para até 2439,64 kg ha⁻¹ em anos de EN, enquanto nos anos de LNs há diminuição da mesma para 325,96 kg ha⁻¹. Os estados do Paraná e Rondônia são os menos afetados pelo ENSO, com rendimentos médios em torno de 2000 e 1000 kg ha⁻¹, respectivamente.