



UNIVERSIDADE ESTADUAL DE CAMPINAS

Faculdade de Engenharia Agrícola

RODRIGO LEME DE PAULO

**DETECÇÃO DE ÍNDICE DE ESTRESSE HÍDRICO UTILIZANDO
INFRAVERMELHO E PROCESSAMENTO DE IMAGENS**

**WATER STRESS INDEX DETECTION USING INFRARED AND IMAGES
PROCESSING**

CAMPINAS

2021

RODRIGO LEME DE PAULO

**DETECÇÃO DE ÍNDICE DE ESTRESSE HÍDRICO UTILIZANDO
INFRAVERMELHO E PROCESSAMENTO DE IMAGENS**

**WATER STRESS INDEX DETECTION USING INFRARED AND IMAGES
PROCESSING**

Dissertação apresentada à Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Mestre em Engenharia Agrícola na área de Máquinas Agrícolas.

Dissertation presented to the Agricultural Engineering Faculty of the University of Campinas in partial fulfillment of the requirements for the degree of Master in Agricultural Engineering the area of Agricultural Machines.

Orientador: Prof. Dr. Daniel Albiero

ESTE TRABALHO CORRESPONDE À
VERSÃO FINAL DA DISSERTAÇÃO
DEFENDIDA PELO ALUNO RODRIGO
LEME DE PAULO E ORIENTADA
PELO PROF. DR. DANIEL ALBIERO

CAMPINAS

2021

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

P285d Paulo, Rodrigo Leme de, 1991-
Detecção de índice de estresse hídrico utilizando infravermelho e processamento de imagens / Rodrigo Leme de Paulo. – Campinas, SP : [s.n.], 2021.

Orientador: Daniel Albiero.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola.

1. Irrigação agrícola. 2. Agricultura de precisão. 3. Irrigação agrícola. 4. Cultivos agrícolas. 5. Engenharia Agrícola - Automação. I. Albiero, Daniel, 1975-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Agrícola. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Water stress index using infrared and images processing

Palavras-chave em inglês:

Agricultural Irrigation

Precision agriculture

Agricultural crops

Agricultural Engineering - Automation

Área de concentração: Máquinas Agrícolas

Titulação: Mestre em Engenharia Agrícola

Banca examinadora:

Daniel Albiero [Orientador]

Angel Pontin Garcia

Eduardo Fernando Nunes

Data de defesa: 26-07-2021

Programa de Pós-Graduação: Engenharia Agrícola

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0001-5086-2432>

- Currículo Lattes do autor: <http://lattes.cnpq.br/0539296428697619>

Este exemplar corresponde à redação final da **Dissertação de Mestrado** defendida por **Rodrigo Leme de Paulo**, aprovada pela Comissão Julgadora em 26 de Julho de 2021, na Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas.

FEAGRI

Prof. Dr. Daniel Albiero – Presidente e Orientador

Prof. Dr. Angel Pontin Garcia – Membro Titular

Dr. Eduardo Fernandes Nunes – Membro Titular

**Faculdade de
Engenharia Agrícola
Unicamp**

A Ata da defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

AGRADECIMENTOS

Gostaria de agradecer a todos que participaram, direta ou indiretamente, da realização desse trabalho. O dedico a quem me acompanhou ao longo de toda jornada, contribuindo com ideias, discussões, questionamentos e principalmente, paciência e sabedoria.

Aos meus pais e irmão, Marcos, Cássia e Rafael, pela base familiar que me foi proporcionada desde sempre, assim como o esforço e os sacrifícios feitos para que eu pudesse alcançar mais essa etapa. O carinho e o amor recebido por eles correspondem ao verdadeiro significado da palavra família.

À minha incrível esposa, Ana Paula, pela dedicação e todo o apoio que necessitei, não apenas desde o primeiro dia desse projeto, mas desde que nos conhecemos. Te agradeço pela parceria, pelo amor e pelo respeito mútuo. Tenho certeza de que alcançaremos nossos sonhos.

Aos familiares, de Campinas ou Franca, pelo apoio e a motivação, pelas risadas e pela paciência.

Ao grupo de pesquisadores do LIC, agradeço o apoio, a união, o espírito de coletividade e as parcerias formadas ao longo de todos os anos que frequentei o laboratório.

Aos colegas de mesa Fabrício Soares e Hugo Rafacho, pela ajuda e a troca de experiências nos problemas de compilação dos algoritmos.

À Karina Braga, pela amizade, pelo carinho, pelas pedaladas e principalmente, por me ajudar nos momentos em que mais precisei. Saiba que seu papel foi importantíssimo neste trabalho.

Ao Bruno Sousa Cerqueira, o Bahia, amigo e aluno de IC, pelo apoio com a programação em Python e por toda a ajuda prestada na segmentação das imagens.

O trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e contou com o apoio do Laboratório de Instrumentação e Controle (LIC) da Faculdade de Engenharia Agrícola da UNICAMP, onde foram realizados testes laboratoriais, o desenvolvimento do sistema e a análise dos resultados.

RESUMO

O monitoramento do estresse hídrico é uma etapa importante da Irrigação de Precisão (IP) e a identificação desse estresse usa técnicas promissoras para o desenvolvimento de sistemas inteligentes de irrigação, racionalizando o uso dos recursos hídricos. O estresse hídrico provoca o fechamento estomatal das plantas e com isso as trocas gasosas são reduzidas fazendo com que a temperatura da planta, geralmente mais baixa, aumente em relação ao ambiente. Uma das maneiras de detectar esse estresse é através da temperatura de dossel, que pode ser medida pela radiação infravermelho emitida pela planta durante a transpiração. O *Crop Water Stress Index* (CWSI), índice quantitativo que utiliza essa diferença entre temperaturas e os limites máximos e mínimos de temperatura em condições de total estresse ou quando a planta não está sob déficit hídrico. Com o objetivo de detectar o estresse hídrico na cultura da rúcula, o presente trabalho busca cruzar informações de sensores infravermelho (IR), que fazem leituras de temperatura numa varredura por toda a área de testes da cultura, com o processamento de imagens RGB, que identifica e segmenta apenas as folhas da planta, gerando um mapa de temperaturas foliares das plantas, um dos parâmetros necessários para o cálculo do CWSI. A altura do conjunto foi verificada através de uma pré-varredura do sensor Ultrassom. Os mapas gerados foram validados através de uma câmera térmica, apresentando erro médio de aproximadamente 0,2°C. A parametrização da equação *Non Water-Stressed Baseline* (NWSB) foi realizada no mesmo microclima em que o experimento, gerando os coeficientes angular e linear iguais a -0,782 e 0,102, respectivamente, fazendo com que os limites máximos e mínimos de temperatura ficassem ligeiramente deslocados da faixa real de temperaturas da planta. Os mapas de estresse gerados apresentaram diferentes valores de CWSI para cada tratamento, mantidos sob diferentes condições hídricas ao longo de todo o ciclo da cultura e o sistema proposto foi capaz de detectar estresse hídrico causado pela disponibilidade de água para a planta, possibilitando a definição do manejo de irrigação pelo CWSI.

ABSTRACT

Water stress monitoring it is an important step of Precision Irrigation (IP) and its identification uses promising techniques for smart irrigation systems development, rationalizing the use of water resources. Water stress causes the plants stomatal closures, so gas exchanges are reduced, causing the plant's temperature, generally lower, to increase in relation to the environment. It is possible to identify water stress by canopy temperature, which can be measured by infrared radiation emitted by the plant during transpiration. The Crop Water Stress Index (CWSI), a quantitative index that uses this difference between temperatures and the maximum and minimum temperature limits under of total stress conditions or when the plant is not under water deficit. To detect water stress in Arugula (*Eruca sativa Miller*), this work seeks to cross-reference information from infrared sensors, which take temperature readings in a scan across the entire crop experimental area, with RGB image processing, which identifies and segments only the leaves of the plant, generating a leaf temperatures map, one of the parameters necessary for the calculation of the CWSI. The system height was verified trough a pre-scan by the ultrasonic sensor. The maps were validated using a thermal camera, with an average error of approximately 0.2°C. The parameterization of the Non Water-Stressed Baseline (NWSB) equation was performed in the same microclimate as the experiment, resulting in angular and linear coefficients equal to -0.782 and 0.102, respectively, causing the maximum and minimum temperature limits to be slightly displaced the actual temperature range of the plant. The stress maps showed different CWSI values for each treatment, maintained under different water conditions throughout the entire crop cycle and the proposed system was able to detect water stress caused by the availability of water for the plant, enabling the irrigation scheduling by CWSI method.

LISTA DE FIGURAS

FIGURA 1- EXEMPLO DE IMAGEM GERADA POR UMA CÂMERA TÉRMICA.....	15
FIGURA 2 - RETAS NWSB PARA DIFERENTES HORÁRIOS DO DIA.....	17
FIGURA 3 - SUPERFÍCIE ARTIFICIAL DE REFERÊNCIA.....	18
FIGURA 4 - DETECÇÃO DE PLANTAS NO SOLO ATRAVÉS DE DIFERENTES PARÂMETROS.....	19
FIGURA 5 - FLUXOGRAMA DO PROCESSO PARA A DETECÇÃO DO ESTRESSE HÍDRICO ATRAVÉS DO CWSI.....	23
FIGURA 6 - ESQUEMATIZAÇÃO DO TESTE EM BANCADA, MOSTRANDO A DISPOSIÇÃO DOS CONJUNTOS DE SENSORES PARA A DETECÇÃO DO ESTRESSE HÍDRICO ATRAVÉS DO CWSI.....	24
FIGURA 7 - SENSOR MLX90614 (A)SEM APARATO (B)COM APARATO METÁLICO.....	25
FIGURA 8 - DISTRIBUIÇÃO DOS SENSORES DE UMIDADE DO SOLO DISPOSTOS NO CENTRO DA ENTRELINHA DE CADA TRATAMENTO DA ÁREA EXPERIMENTAL.....	31
FIGURA 9 - ALTURA DO SISTEMA AO LONGO DO CICLO DA CULTURA.....	32
FIGURA 10 - MAPA DE TEMPERATURAS GERADOS PELO SENSOR IR (A) SEM APARATO E (B) COM APARATO NOS TRATAMENTOS 1,2 E 3 DA ÁREA EXPERIMENTAL, ONDE O CVA DE CADA TRATAMENTO FOI CC-5%, CC-10% E CC-15%, RESPECTIVAMENTE.....	33
FIGURA 11- MAPA TÉRMICO DA ÁREA EXPERIMENTAL, MOSTRANDO PONTOS DE SOLO, PLANTA OU A COMBINAÇÃO DESTES. O MAPA FOI GERADO NO 25DAP, FASE FINAL DA CULTURA.....	34
FIGURA 12- IMAGENS DA CULTURA EM DIFERENTES ESTÁGIOS DE DESENVOLVIMENTO, UTILIZADAS NA AVALIAÇÃO DOS MÉTODOS DE PROCESSAMENTO.....	35
FIGURA 13- IMAGENS <i>TARGET</i> UTILIZADAS COMO REFERÊNCIA PARA A AVALIAÇÃO DAS ABORDAGENS, ONDE (A) OS PIXELS FORAM SEGMENTADOS DENTRO DA MÉDIA DOS 10 PIXELS SELECIONADOS E (B) RECEBERAM VALOR IGUAL A 1.....	35
FIGURA 14 - IMAGENS SEGMENTADAS GERADAS POR TODOS OS MÉTODOS AVALIADOS, UTILIZANDO A MESMA IMAGEM RGB. O MÉTODO EXG(RGB) APRESENTOU AS MELHORES MÉTRICAS E FOI USADO NESTE TRABALHO, ENQUANTO O NDI MANUAL FOI O PIOR MÉTODO AVALIADO.....	38
FIGURA 15 - MAPA DE TEMPERATURA FOLIARES GERADO ATRAVÉS DO CRUZAMENTO DO MAPA DE TEMPERATURAS DA ÁREA EXPERIMENTAL COM A IMAGEM SEGMENTA DA CULTURA- 25DAP.....	39
FIGURA 16 - IMAGEM TÉRMICA GERADA, NO 25DAP, PELA CÂMERA IR (A)ORIGINAL E (B) REDIMENSIONADA COM A SOBREPOSIÇÃO DA IMAGEM PROCESSADA PARA A SEGMENTAÇÃO DAS PLANTAS.....	40
FIGURA 17 - MONITORAMENTO DA TEMPERATURA AMBIENTE, DE OBJETO E DA UMIDADE RELATIVA PARA A BANCADA AUXILIAR NA PARAMETRIZAÇÃO DE NWSB.....	41
FIGURA 18- PARAMETRIZAÇÃO DA <i>NON WATER-STRESSED BASELINE</i> DEFINIDA PARA O AMBIENTE PROTEGIDO (NWSB _p).....	41
FIGURA 19 - PARAMETRIZAÇÃO DA <i>NON WATER-STRESSED BASELINE</i> DEFINIDA PARA O AMBIENTE DESPROTEGIDO (NWSB _d).....	42
FIGURA 20 - MAPA DE CWSI DA ÁREA EXPERIMENTAL EM AMBIENTE PROTEGIDO GERADO PARA O 25DAP, EM VARREDURA REALIZADA AS 12:00HR, HORÁRIO COM MELHORES RESULTADOS DE LEITURA.....	44
FIGURA 21 - MAPA DE CWSI DA ÁREA EXPERIMENTAL EM AMBIENTE DESPROTEGIDO, GERADO PARA O 25DAP. OS LIMITES SUPERIOR E INFERIOR DE NWSB _d NÃO INDICARAM VALORES REAIS DE TEMPERATURA E O CWSI MÍNIMO CALCULADO FOI 0,6, CORRESPONDENDO À SITUAÇÃO SEM ESTRESSE HÍDRICO.....	45
FIGURA 22 - MAPA DE CWSI GERADO PARA O 25DAP, UTILIZADO O MÉTODO EMPÍRICO PARA OBTER AS T _{MAX} E T _{MIN} ATRAVÉS DE SUPERFÍCIES NATURAIS DE REFERÊNCIA. UMA DAS FOLHAS FOI MOLHADA COM ÁGUA PARA SIMULAR A 100% DE TRANSPIRAÇÃO E A OUTRA COM VASELINA PARA BLOQUEAR TOTALMENTE A TRANSPIRAÇÃO FOLIAR.....	46
FIGURA 23 - MONITORAMENTO DA UMIDADE PARA CADA TRATAMENTO AO LONGO DO CICLO DA CULTURA, ONDE OS VALORES DE CVA FORAM NORMALIZADOS PARA EVITAR DIFERENÇAS DE LEITURAS ENTRE OS SENSORES UTILIZADOS.....	47
FIGURA 24 - NÍVEIS DE ESTRESSE HÍDRICO AO LONGO DE TODO O CICLO DA RÚCULA. A UMIDADE DO SOLO FOI NORMALIZADA PELA CAPACIDADE DE CAMPO DE CADA TRATAMENTO, IGUALANDO ASSIM AS REFERÊNCIAS UTILIZADAS PARA A MEDIÇÃO.....	48
FIGURA 25 -GRÁFICOS DA MÉDIA MÓVEL EXPONENCIALMENTE PONDERADA DO CWSI E DO CVA DE CADA TRATAMENTO.....	49
FIGURA 26 - ANÁLISE DE REGRESSÃO E RESIDUAL PARA A NWSB PARAMETRIZADA EM AMBIENTE PROTEGIDO...65	65
FIGURA 27 - ANÁLISE DE REGRESSÃO E RESIDUAL PARA A NWSB PARAMETRIZADA EM AMBIENTE DESPROTEGIDO.	65

Sumário

1. INTRODUÇÃO	10
2. REVISÃO BIBLIOGRÁFICA	12
2.1. Sistemas de Irrigação e Irrigação de Precisão	12
2.2. Identificação de estresse hídrico e Monitoramento	13
2.3. Sensoriamento térmico	14
2.4. <i>Crop Water Stress Index</i> - CWSI.....	16
2.5. Processamento de imagens.....	18
2.6. Sensoriamento ultrassônico	21
3. METODOLOGIA.....	23
3.1. Descrição dos Sensores e Equipamentos utilizados	24
3.2. Mapa de Temperaturas Foliares (MTF)	26
3.2.1. Mapa Térmico de Solo/Planta	26
3.2.2. Processamento de Imagens	26
3.2.3. Validação do MTF.....	29
3.3. Parametrização da <i>Non Water-Stressed Baseline</i> (NWSB)	29
3.4. Cálculo do CWSI.....	30
4. RESULTADOS E DISCUSSÃO.....	32
4.1. Mapa de Temperaturas Foliares.....	32
4.1.1. Altura das plantas e do conjunto	32
4.1.2. Mapa Térmico de Solo/Planta	33
4.1.3. Processamento de Imagens	35
4.1.4. Validação do MTF	39
4.2. Equação NWSB.....	40
4.3. CWSI	44
5. CONCLUSÕES	50
6. REFERÊNCIAS.....	51
7. APÊNDICE 1	61
8. APÊNDICE 2	64

1. INTRODUÇÃO

A Irrigação de Precisão (IP) se mostra promissora por monitorar e controlar o uso da água levando em conta a variabilidade espacial e a necessidade individual de cada planta (ABIOYE *et al.*, 2020). Sistemas que utilizam menor quantidade de água e possuem alta eficiência energética são realidade e nos últimos anos, através do desenvolvimento da tecnologia nesse setor, foi possível tornar os sistemas de irrigação que usam a IP mais competitivos, facilitando o acesso do agricultor (MASSERONI; ARBAT; DE LIMA, 2020).

Na IP, há o monitoramento de diversas variáveis e condições do conjunto solo-planta-ambiente para fornecer informações detalhadas sobre a necessidade hídrica da cultura. A interpretação desses dados auxilia na tomada de decisões sobre o manejo de irrigação (ZACEPINS, A; STALIDZANS, E; MEITALOV, 2012). A utilização da IP deve resultar em informações sobre onde, quanto e quando irrigar (GALIOTO; RAGGI; VIAGGI, 2017).

A detecção do estresse hídrico é um dos parâmetros importantes num manejo de IP, para garantir que as plantas não passem por níveis de estresse que prejudicam a produtividade ou até mesmo a qualidade da produção (RASSINI, 2011). Para algumas culturas como a da oliveira (AGAM *et al.*, 2013), e na viticultura (BASSOI *et al.*, 2011), estudos mostraram que um certo grau de estresse hídrico faz com que a planta produza mais polifenóis e a acidez de seus produtos seja menor, beneficiando suas qualidades (AGAM *et al.*, 2013; BASSOI *et al.*, 2011). Entretanto, níveis elevados de estresse hídrico, além de afetar o desenvolvimento das culturas, podem fazer com que estas atinjam seu ponto de murcha permanente (KRAMER; O'LEARY, 1970).

Existem algumas formas de detectar o estresse hídrico, podendo-se destacar os métodos que medem a tensão de água no solo, o potencial de condução estomatal e até mesmo o fluxo de seiva (ABIOYE *et al.*, 2020). Porém, apesar de serem considerados métodos padrões, a medição da tensão de água no solo refere-se apenas ao meio de cultura e não à planta em si (KACIRA; LING; SHORT, 2002). Já os métodos de condução estomatal e fluxo de seiva são pouco aplicáveis no campo, uma vez que são ensaios destrutivos e necessitam de instrumentações específicas (COSTA, J. MIGUEL; GRANT; CHAVES, 2013).

Desde 1964, a temperatura da planta pode ser um dos parâmetros para a identificação do estresse hídrico (JACKSON, R. D. *et al.*, 1981), que provoca o fechamento estomatal das plantas para que as folhas reduzam a perda de água por transpiração. Entretanto, ao reduzir as trocas gasosas, o fechamento dos estômatos faz com que a temperatura foliar aumente em relação à temperatura ambiente. O *Crop Water Stress Index* (CWSI), indicador que

utiliza essas temperaturas e dados meteorológicos como parâmetros para identificar o estresse hídrico das plantas, possibilita quantificar o nível de estresse pela normalização entre as temperaturas máximas, quando não há evaporação, e mínimas da planta, quando a evaporação está em seu potencial máximo. KACIRA, LING, SHORT (2002) detectaram o estresse hídrico em flores apontando uma rápida resposta do sistema, antecipando a identificação em até 2 dias, quando comparado aos métodos convencionais, evidenciando a vantagem da utilização desse índice.

A literatura acerca do CWSI é relativamente vasta, os estudos se concentram desde as formas de se obter o índice (ALSALAM *et al.*, 2017; COSTA, J. MIGUEL; GRANT; CHAVES, 2013; GARCÍA-TEJERO *et al.*, 2018), a avaliação do comportamento de culturas em relação ao CWSI (BEN-GAL *et al.*, 2009; CAMOGLU; DEMIREL; GENC, 2018; ÇOLAK *et al.*, 2015; DA SILVA *et al.*, 2018) e maneiras de utilizar a informação contida nele em sistemas de manejo de irrigação (BALLESTER; JIMÉNEZ-BELLO; *et al.*, 2013; ERDEM *et al.*, 2006; FATTAHI *et al.*, 2018). Todos esses estudos têm em comum a utilização de metodologias semelhantes para a aquisição dos dados, como o uso de sensores infravermelhos (IR) e câmeras térmicas para obter as temperaturas foliares das plantas.

Fatores como o alto custo de aquisição, a dependência do câmbio internacional, a dificuldade de operação e a sensibilidade à calibração são entraves na utilização de câmeras térmicas para se obter um mapa térmico, enquanto os sensores IR são mais acessíveis e simples. Portanto, o objetivo geral deste trabalho é desenvolver um sistema de detecção de estresse hídrico utilizando índices de temperatura foliar obtidos por meio do cruzamento das respostas dos sensores infravermelho com o processamento de imagens. Sendo os objetivos específicos: (i) Verificar se a utilização de um sensor IR com campo de visão (FOV) direcional possibilita a medição da temperatura foliar da cultura; (ii) Parametrizar a equação *Non-Stressed Water Baseline* (NWSB) para a cultura da rúcula e definir seus limites; (iii) Verificar se o mapa de temperaturas foliares gerado pelos sensores permite o cálculo do CWSI e a identificação de estresse hídrico em diferentes condições hídricas.

A estrutura deste trabalho foi organizada da seguinte maneira: A Seção 2 apresenta a revisão bibliográfica na qual este foi embasado. A Seção 3 apresenta a metodologia usada para os experimentos. A Seção 4 apresenta e discute os resultados obtidos, analisando-os com a literatura. A Seção 5 apresenta a conclusão do trabalho e elucida oportunidades de estudos futuros que foram geradas através deste trabalho.

2. REVISÃO BIBLIOGRÁFICA

2.1. Sistemas de Irrigação e Irrigação de Precisão

A irrigação de culturas tem o importante papel de suplementar a quantidade de água presente no solo para que as culturas possam se desenvolver de acordo com suas necessidades hídricas.

Sistemas convencionais de irrigação, onde são aplicadas quantidades uniformes sobre toda a área da cultura, além de consumirem uma maior quantidade de água são menos eficientes (SINGH, 2021) e desconsideram a variabilidade espacial e individual da cultura (KUMAR, ANUSHA *et al.*, 2018). Nesses sistemas, pode-se destacar os métodos de irrigação superficiais, como aspersores, pivô e gotejamento, que são potenciais causadores de erosões, lixiviamentos e consequentemente provocam a diminuição de produtividade, quando a água é aplicada em excesso (ADAMALA; RAGHUWANSHI; MISHRA, 2014). Além destes, temos ainda os métodos subsuperficiais, como gotejamento subsuperficial e de raízes, que são mais eficientes quando comparados aos métodos superficiais (ABIDIN *et al.*, 2013; ABIOYE *et al.*, 2020; SEZEN *et al.*, 2014).

A irrigação de precisão (IP) é responsável por integrar informações e tecnologias de controle à irrigação para otimizar o uso da água (ZACEPINS, A; STALIDZANS, E; MEITALOVS, 2012), uma vez que esta considera fatores como variações espaciais nos tipos, texturas e quantidade de nutrientes do solo, relevo, clima e a necessidade hídrica das plantas (ABIOYE *et al.*, 2020). Além disso, a IP não é uma tecnologia específica, e sim um tipo de manejo, pois é adaptativa uma vez que é aplicável em todos os métodos de irrigação e em todas as culturas (SMITH; BAILLIE, 2009).

Os processos de IP envolvem quatro etapas importantes, sendo elas: Obtenção de dados; Interpretação dessas informações; Controle de parâmetros; Avaliação dos resultados, como por exemplo, produtividade e qualidade do produto final (GALIOTO; RAGGI; VIAGGI, 2017; SMITH; BAILLIE, 2009). De acordo com (GALIOTO; RAGGI; VIAGGI, 2017), a principal resposta da IP é a informação de quando e quanto o sistema de irrigação deve atuar. Segundo a escala do sistema e o porte das culturas, a IP consegue fornecer essas informações em áreas/setores com diferentes manejos ou até mesmo individualizado para a planta.

2.2. Identificação de estresse hídrico e Monitoramento

Ao aplicar o conceito de IP, a aquisição de dados é necessária para monitorar fatores como a quantidade de água disponível para a cultura, a umidade do solo e dados meteorológicos locais. BELLVERT *et al.*, (2013) afirmam que as propriedades do solo, a produtividade e os índices espectrais vegetativos também podem ser usados como parâmetros que identificam a variabilidade espacial no ambiente de produção.

A identificação do estresse hídrico é importante para que a planta não tenha seu desenvolvimento prejudicado, podendo causar até a murcha permanente da mesma. Por outro lado, trabalhos como os de AGAM *et al.*, (2013); BEN-GAL *et al.*, (2009) ressaltam a melhora na qualidade do azeite que um certo grau de estresse hídrico controlado pode provocar em oliveiras. Existem alguns métodos que detectam o estresse hídrico por diferentes maneiras, via solo, via clima ou via planta (ABIOYE *et al.*, 2020).

O monitoramento via solo utiliza princípios como a tensão de água no solo (BASSOI *et al.*, 2011; SANTOS *et al.*, 2020), o conteúdo volumétrico de água (CVA) e sua relação com a capacitância do solo (CIEZKOWSKI *et al.*, 2020; EID *et al.*, 2021), reflectometria no domínio de tempo (*TDR*), que emite pulsos magnéticos e mede o tempo de retorno desses pulsos (CATALDO *et al.*, 2017; WALCZAK; LIPÍŃSKI; JANIĆ, 2021).

O monitoramento via clima tem como principal parâmetro a Evapotranspiração de Referência (ET_0), que estima a quantidade de água perdida tanto pela planta como pelo solo, calculada através de parâmetros como radiação solar, velocidade do vento, umidade do ar e calor latente. Ao ser multiplicada pelo coeficiente de cultura K_c , tem-se a Evapotranspiração Atual da cultura (ET_c) (ADAMALA; RAGHUWANSHI; MISHRA, 2014; YODER; ODHIAMBO; WRIGHT, 2005).

O monitoramento via plantas baseia-se nos índices vegetativos como o potencial de água na folha (ψ_L) e a condutância estomatal (G_s) (BELLVERT *et al.*, 2013; JHA; KUMAR; INES, 2018), o NDVI (*Normalized Difference Vegetation Index*) (AGAM *et al.*, 2013) e fluxo de seiva (BALLESTER; CASTEL; *et al.*, 2013).

Os métodos supracitados são considerados como o padrão de medições para a aquisição de dados, porém, de acordo com KACIRA, LING, SHORT (2002), o monitoramento via solo monitora apenas o meio da cultura, e não o estado da cultura em si. Situações onde há o desequilíbrio de nutrientes e sais no solo podem fazer com que haja água disponível para a planta, porém esta não consiga absorver e sofra estresse (LUCCHESI *et al.*,

(2018). BEN-GAL *et al.*, (2009) relatam que a heterogeneidade nas zonas de raízes como um fator desfavorável ao de uso dos métodos via solo.

O monitoramento através do clima se mostra bastante sensível à variações na velocidade do vento e nuvens, que afetam a radiação incidente nas plantas (JONES, 2004). Diversos autores afirmam que métodos como a medição de ψ_L , de G_s e do fluxo de seiva são métodos caros, que não permitem automação e são pouco aplicáveis em campo, já que são destrutíveis e necessitam de equipamentos específicos, como uma câmera de pressão (BALLESTER; JIMÉNEZ-BELLO; *et al.*, 2013; BEN-GAL *et al.*, 2009; JIMÉNEZ-BELLO *et al.*, 2011; VEYSI *et al.*, 2017; YODER; ODHAMBO; WRIGHT, 2005).

Ainda há outra maneira de monitoramento via planta, onde JACKSON, R. *et al.*, (1981) afirmam que desde 1964 é possível identificar estresse hídrico através de dados de temperatura das plantas. Um dos mecanismos de defesa contra o estresse hídrico provoca o fechamento estomatal para que as folhas reduzam a perda de água por transpiração, e consequentemente a temperatura foliar aumenta em relação à temperatura ambiente (SANTOS *et al.*, 2020). É importante ressaltar que esta não é a única defesa que provoca o fechamento estomatal das plantas.

Através da diferença entre essas temperaturas e de parâmetros como umidade relativa (UR) do ar, pode-se utilizar o CWSI, um indicador que possibilita a quantificação do estresse hídrico na planta, baseado em normalizações de temperatura (IDSO, SHERWOOD B., 1982; JACKSON, R. D. *et al.*, 1981). Este índice será explicado na seção 2.4.

2.3.Sensoriamento térmico

Ao utilizar o CWSI como método para se monitorar o estresse hídrico, deve-se adotar o uso de sensores térmicos para a aquisição de dados. Estes podem ser sensores de contato, como é o caso dos sensores usados por PALAZZARI *et al.*, (2017), que desenvolveram um sensor de clipe para medir as temperaturas folhares e transmiti-las por uma rede sem fio de sensores (*WSN*).

Os sensores IR podem ser utilizados como termômetros por serem capazes de medir a radiação infravermelho e fazer a conversão de sinais elétricos em temperatura. As vantagens de seu uso são a rapidez sem a necessidade de contato entre o sensor e a superfície a ser medida (RUD *et al.*, 2014; THAPA *et al.*, 2018; WANG, XUEZHI *et al.*, 2010a). Os primeiros estudos que utilizaram os sensores IR para medir a temperatura foliar foram MONTEITH, SZEICZ

(1962), que avaliaram a emissão de radiação em superfícies naturais como copas de árvores, solo descoberto ou com grama.

Desde então, estudos na área agrícola utilizam esse tipo de sensores para medir temperaturas de plantas, de solo, de equipamentos ou até mesmo de reações químicas (DANTAS, R. T E ROMANA RAO, 1994; FERNANDES, 2010).

THAPA *et al.*, (2018) utilizaram imagens infravermelho obtidas por satélites para relacionar a produção de trigo nos Estados Unidos com a temperatura de dossel das plantações e detectaram que plantas que tiveram menores temperaturas resultaram em maiores produtividades. MALLICK *et al.*, (2018) começaram a avaliar uma nova metodologia utilizando sensores IR para correlacionar temperaturas e a transpiração da planta, uma vez que os modelos baseados em balanço de energia são muito sensíveis à condutância aerodinâmica. Os autores encontraram correlações com R^2 próximo a 0,90 entre a temperatura da planta e seus índices evaporativos.

As câmeras térmicas também são uma alternativa para identificar o stress hídrico das plantas (ABIOYE *et al.*, 2020). As imagens térmicas também são criadas a partir da emissão de radiação dos corpos, a diferença de temperaturas é mostrada por uma escala de cores que identifica pontos mais quentes e frios. A exemplo de imagens térmicas temos a Figura 1.




Figura 1- Exemplo de imagem gerada por uma câmera térmica

Fonte: JIMENEZ-BELLO, et al (2011)

ALCHANATIS *et al.*, (2009) avaliaram a qualidade de imagens térmicas tiradas ao longo do dia, de diferentes posições, encontrando o horário entre 12:00h e 14:00h como os melhores horários para se obter as imagens. Ressalta-se a importância em relação à qualidade das imagens geradas, uma vez que câmeras térmicas são muito sensíveis (TANDA; CHIARABINI, 2019) e o cuidado necessário com a resolução da imagem utilizada, como

avaliado por BELLVERT *et al.*, (2013) e CIEZKOWSKI *et al.*, (2020), que utilizaram imagens aéreas e identificaram uma resolução ideal para que seja possível usar esse tipo de metodologia.

BALLESTER, CASTEL (2013) e JIMÉNEZ-BELLO *et al.*, (2011) utilizaram as imagens térmicas para identificar estresse hídrico em pomares de cítrus e caqui, encontrando diferenças entre a temperatura da planta e do ambiente de até 4,4°C. BERNI *et al.*, (2009) fizeram o mesmo estudo para cultura de oliveiras e identificaram variação espacial no CWSI da cultura, com valores entre 0,1 e 0,8. Já QUEBRAJO *et al.*, (2018) avaliaram imagens térmica em beterrabas e concluíram que o monitoramento utilizando a temperatura das plantas identificou estresse hídrico, porém notaram que as variações do tipo e estrutura de solo alteravam o nível desse estresse e consequentemente, a qualidade dos frutos era distinta.

2.4. Crop Water Stress Index - CWSI

O CWSI é definido por JACKSON, *et al.*, (1981) como sendo $1 - E/E_0$, onde E é a evapotranspiração atual e E_0 a evapotranspiração potencial, este índice é uma normalização entre as temperaturas máximas, quando a planta está sob estresse hídrico e mínimas, quando a planta tem água disponível. Em termos de energia, o CWSI pode ser calculado pela Equação 1.

$$CWSI = 1 - \frac{\Delta + Y^*}{\Delta + Y(1 + r_c/r_a)} \quad [\text{Equação 1}]$$

Onde Δ é o coeficiente angular da relação entre vapor de pressão de saturação e a diferença de temperaturas ($T_{dossel} - T_{ambiente}$), Y é a constante psicrométrica [$Pa \cdot ^\circ C^{-1}$], r_a é a resistência de transporte de vapor do dossel [$s \cdot m^{-1}$] e r_c é a resistência de aerodinâmica do ar [$s \cdot m^{-1}$].

De maneira simplificada, o CWSI pode ser calculado baseado na diferença entre temperaturas foliar (T_F) e do ambiente (T_A), como mostra a Equação 2. Originalmente, é considerada a temperatura de dossel (T_C) da planta, mas nesse trabalho foi considerada T_F pelo porte da cultura avaliada.

$$CWSI = \frac{(T_F - T_A)_{LL} - (T_F - T_A)_{UL}}{(T_F - T_A)_{UL} - (T_F - T_A)_{LL}} \quad [\text{Equação 2}]$$

Onde $(T_F - T_A)_{LL}$ e $(T_F - T_A)_{UL}$ são os limites superiores e inferiores, encontrados pela Equação da *Non-Water-Stressed-Baseline* (NWSB) que, de acordo com (IDSO, SHERWOOD B., 1982) correlaciona a diferença entre as temperaturas foliares e do ambiente com o déficit de pressão de vapor (VPD). Ainda segundo o autor, essa equação é específica para cada cultura, pela maneira como elas interagem com o ambiente. BALLESTER; JIMÉNEZ-BELLO *et al.*, (2013) identificaram que plantas mais lenhosas são menos sensíveis à variação no VPD, em

estudo feito com as culturas de cítrus e caqui. Atualmente, existe na literatura a parametrização de NWSB para diversas culturas, como abacaxi, tomate, berinjela, alface, soja, milho, mostarda, entre outros (ADEYEMI *et al.*, 2018; ÇOLAK *et al.*, 2015; DA SILVA *et al.*, 2018; FATTAHI *et al.*, 2018; KUMAR, NAVSAL *et al.*, 2020).

TESTI *et al.*, (2008) notaram que os coeficientes da NWSB variam ao longo do dia, fazendo com que ambos limites $(T_F - T_A)_{LL}$ e $(T_F - T_A)_{UL}$ sejam alterados. Como mostra a Figura 2, cada horário possui uma Equação NWSB com coeficientes distintos, e o uso dos limites superiores e inferiores corretos faz com que o cálculo do CWSI tenha menos variações.




Figura 2 - Retas NWSB para diferentes horários do dia.

Adaptado de: Testi et al. (2008)

Para a realização deste trabalho, uma simplificação do modelo adotando apenas uma equação média diária foi utilizado, assim como nos trabalhos de ERDEM *et al.*, (2006); FATTAHI *et al.*, (2018) que parametrizaram suas equações apenas com valores médios diários para definir o manejo de irrigação na cultura do milho, como SEZEN *et al.*, (2014) na cultura de pimenta. CIEZKOWSKI *et al.*, (2020) também buscaram adaptar o CWSI para ser usado em pântanos com a parametrização de NWSB de apenas um valor diário, porém concluíram que devido às complexidades do sistema pantanoso, deve-se usar outro método de monitoramento paralelo ao CWSI para indicar o estresse hídrico nesse tipo de ambiente.

Existem outras formas de obter os limites superior e inferior da diferença de temperaturas, como demonstrado por BERNI *et al.*, (2009), levando em conta equações analíticas dependentes da radiação solar incidente e da resistência aerodinâmica das folhas.

Numa aproximação empírica, JACKSON, RAY D. (1982) definiu o limite superior como sendo 5°C maior que a temperatura do ar. Já o limite inferior é obtido através da temperatura de uma superfície artificial de referência, completamente molhada com água

(Figura 3). WANG e GARTUNG (2010), se basearam nessa aproximação, porém consideraram os limites superiores como a temperatura da folha quando sua evaporação é zero, onde os autores passaram uma camada de vaselina na superfície da folha (Figura 3).

DA SILVA *et al.*, (2018) compararam esses métodos avaliando a cultura de tomates e concluíram que, estatisticamente, não são diferentes entre si. Outros autores como ADEYEMI *et al.*, (2018); AGAM *et al.*, (2013); ALCHANATIS *et al.*, (2009); RUD *et al.*, (2014) também utilizaram as maneiras empíricas e analíticas para calcular o CWSI, e apesar de corroborar com DA SILVA *et al.*, (2018), identificaram que o comportamento deles ao longo do dia varia de forma distinta, onde a aproximação empírica apresenta dados mais consistentes, porém a necessidade do uso de superfícies artificiais dificulta a automação e o monitoramento do estresse hídrico.




Figura 3 - Superfície Artificial de Referência.
Adaptado de (WANG, XUEZHI *et al.*, 2010a)

2.5. Processamento de imagens

A visão computacional é um processo que tem como entrada uma imagem e uma interpretação total ou parcial dessa imagem como saída (MARENGONI; STRINGHINI, 2010). É necessário enfatizar que o processamento de imagens por si só não pode ser considerada visão computacional. O processamento de imagens é feito a partir do uso de uma câmera ótica, que capta a imagem do objeto. Posteriormente, uma lógica de programação é utilizada para aplicar filtros, com a finalidade de eliminar ruídos, destacar objetos de interesses, entre outros. Na maioria dos casos, são extraídos parâmetros como cor, forma, tamanho e textura.

As câmeras multiespectrais são capazes de captar imagens em diversos espectros, também chamados de bandas, a saber: Vermelho (R), Verde (G), Azul (B), uma composição vermelho-verde-azul (RGB), Ultravioleta (UV), Infravermelho Normal (IR), Infravermelho médio (MIR) ou ainda o Infravermelho próximo (NIR). Cada uma das bandas fornecem

informações distintas, uma vez que os objetos têm respostas específicas à absorção ou refletância do espectro analisado (MOREIRA, 2011).

COSTA, CORRADO *et al.*, (2011) publicaram uma revisão das principais pesquisas que utilizavam o processamento de imagens e a visão computacional para identificar formas de frutos, vegetais e castanhas. Além de propor um novo modelo de análise para correlacionar estas formas à genética, conformidade com padrões comerciais e até mesmo a seleção de produtos para serem clonados, neste artigo, os autores ainda citam uma dificuldade de se utilizar a visão computacional no meio agrícola devido às variações de iluminação e as irregularidades nas formas. PERISSINI (2018) também fez uma análise com 26 técnicas de processamento de imagens e encontrou diversos resultados promissores, porém que dependem da disponibilidade computacional e do contexto em que serão aplicadas.

Segundo PERISSINI (2018), as segmentações através de cada parâmetro tem suas vantagens e desvantagens, devendo ser utilizadas de acordo com a informação que se busca (Figura 4). A segmentação por forma, é pouco sensível a iluminação e é muito usada para detectar plantas pelo formato das folhas, a variação de tamanhos das folhas ou até mesmo a sobreposição de folhas afetamos resultados. Na segmentação por textura, a distinção entre solo e planta é relativamente simples se usado imagens de alta resolução, uma vez que há uma grande diferença de textura entre os dois. A segmentação por intensidade luminosa tem em laboratório bons resultados quando aplicado para a detecção de plantas no solo, isso se deve ao fato de usar imagens monocromáticas e realizar a detecção através de um valor de corte (*threshold*). No entanto, o uso desse tipo de segmentação em ambientes externos se torna altamente vulnerável às condições de iluminação. Já a segmentação por cores, costuma apresentar melhores resultados na detecção de plantas (principalmente as verdes), já que o solo e demais resíduos são geralmente marrons ou cinza. Porém, assim como a segmentação por intensidade luminosa, a segmentação por cores é dependente das condições de iluminação. e o uso de aparatos que reduzem essa dependência, como iluminação complementar, dificultam o uso dessa técnica em ambientes externos.




Figura 4 – Detecção de plantas no solo através de diferentes parâmetros.

Adaptado de Perissini (2018)

A utilização da visão computacional para o reconhecimento de padrões de plantas invasoras no campo é promissora, as taxas de acerto são de cerca de 80% (SANTOS, 2009). O mesmo ocorre no monitoramento da florada de pessegueiros através do processamento de imagens aéreas realizadas através de uma câmera multiespectral (NIR, B, G) capitando imagens no período diurno, com ou sem a presença de nuvens, os resultados indicam uma taxa de 84,3% de sucesso na detecção de flores das arvores (HORTON *et al.*, 2017).

O processamento de imagens para a detecção de flores em macieiras foi realizado por DIAS, TABB e MEDEIROS (2018), onde os autores utilizaram o *threshold* de cores e uma rede neural convolucional, que além de cores, analisou outros aspectos morfológicos da planta e reduziu a dependência de iluminação dos algoritmos para processar imagens.

Visto que a intensidade luminosa e os ruídos vindos das condições ambientais são um problema recorrente em muitos estudos, métodos de constância de cor têm sido avaliados, como em RATNASINGAM e MCGINNITY (2012), que testaram modelos capazes de extrair a cromaticidade das imagens de forma eficiente, mesmo em ambientes com interferência da iluminação externa. Os algoritmos foram testados com base na separabilidade e perceptibilidade das cores em diferentes tipos de iluminações, e notou-se uma boa performance ao compará-los com outros algoritmos apontados no trabalho. Por outro lado, GIJSENIJ, GEVERS e WEIJER (2011) analisaram métodos de correlação de cor como os *Static-Based*, *Gamu-Based* e *Physics-Based*, avaliando-os por critérios como custo computacional, acurácia da estimativa e a complexidade de implementação, e concluindo que cada modelo analisado possui seus prós e contras, que vão desde a não necessidade de treinamento prévio até a dificuldade de implementação pela baixa velocidade de execução. Esta conclusão foi posteriormente corroborada por PERISSINI (2018).

JAFARI, BAKHSHIPOUR e HEMMATIAN (2014) avaliaram os modelos de cores HSV (*Hue, Saturation e Value*) e YCrCb sob diferentes condições de iluminação para diferenciar flores de açafrão do solo. Foram analisadas imagens RGB e os *thresholds* para a segmentação das imagens foram obtidos a partir do seu histograma de cores, pelos valores mínimos entre a saturação da imagem (S) e sua cromaticidade na banda azul (Cb). Seus resultados mostraram que o modelo YCrCb apresentou acurácias melhores do que o HSV e que a aplicação das redes neurais artificiais tornou o processo de classificação mais robusto em relação à perda de dados e outros ruídos que podem afetar a qualidade das imagens.

AURELIANO NETTO *et al.*, (2018) avaliaram a eficiência de três diferentes índices de vegetação (ExG, ExGR e NDI) na diferenciação entre as folhas de milho e o solo, usando diferentes modelos de limiarização, *Otsu*, *Ridler* e *Triangle*. A acurácia foi medida pelo *K-Means*, que seleciona os pixels da imagem segundo similaridades e características como intensidade de cor e a distância relativa entre eles (MARY; PADMA; JOHN, 2013). Seus resultados foram considerados satisfatórios para as condições analisadas, contudo, os modelos NDI e ExGR apresentaram melhores acurácias na segmentação de imagens RGB quando comparados ao índice ExG.

ZHENG *et al.*, (2018) realizaram um trabalho utilizando os índices de vegetação mostrados na Tabela 1 em imagens multiespectrais obtidas por VANTs para estimar a quantidade de Nitrogênio na planta de arroz ao longo de seu desenvolvimento. Ao analisar os resultados obtidos pelo RMSE e R^2 , concluíram que o índice de vegetação NGRDI aplicado à imagem RGB mostrou satisfatórias estimativas das quantidades de N presentes nas plantas e que o índice GNDVI aplicado à banda NIR apresentou razoável performance ao longo do desenvolvimento dessa cultura.

Tabela 1 - Índices usados por (ZHENG et al.,2018)

Índice Vegetativo	Fonte
GNDVI (<i>Green Normalized Difference Vegetation Index</i>)	(GITELSON; KAUFMAN; MERZLYAK, 1996)
NExG (<i>Normalized Excess Green Index</i>)	(RASMUSSEN <i>et al.</i> , 2016)
NGRDI (<i>Normalized Green-Red Difference Index</i>)	(TUCKER, 1979)
ENDVI (<i>Enhanced Normalized Difference Vegetation Index</i>)	(GERARD <i>et al.</i> , 2002)

2.6.Sensoriamento ultrassônico

O mapeamento de ambientes ou o posicionamento de máquinas agrícolas em linhas de plantio, são comumente estudados através de sensores com diferentes princípios de funcionamento. Os sensores mais utilizados no segmento agrícola são: os sensores a laser, o sensor de distância do tipo PSD (*Position Sensing Detector*) e os sensores de ultrassom (TANGERINO, 2009). Estes últimos se mostram bastante promissores no uso agrícola, por não serem afetados pela luminosidade e possuírem rápida resposta (MOUSAZADEH, 2013), além de terem obtido erros de medição variando entre 0,3 e 0,7% (KOVAL; VAŇUŠ; BILÍK, 2016).

Como exemplo, temos o uso dos sensores ultrassom em um sistema de controle de altura de pulverização para medir a distância entre a barra pulverizadora e as plantas de algodão (QUEIRÓS, 2010), e o uso dos sensores para medir em tempo real a altura de plantas de mirtilo

e consequentemente reduzir as perdas durante a colheita, sob a justificativa do aumento no porte das plantas, que cresceram entre 5 e 25cm de altura nos últimos anos (CHANG *et al.*, 2017). Os autores conseguiram reduzir o erro médio durante a colheita de 5,7cm para 1,7cm.

Através desse tipo de sensores que RUIZ (2019) desenvolveu um pulverizador segmentado vertical para a cultura de café, cuja distância de aplicação pode ser controlada bico a bico, sendo mantida constante através de um sistema de controle e melhorando a qualidade da aplicação. Seus resultados mostraram uma redução no erro quadrático integrado de 68% se comparados à uma operação sem nenhum tipo de controle, indicando uma melhoria na área de cobertura sem aumentar o consumo de calda.

ALSALAM *et al.*, (2017) projetaram um VANT para agricultura de precisão que identificava parâmetros de coloração e a presença de plantas daninhas. Os autores utilizaram um sensor ultrassônico para corrigir a altura de voo e manter a distância da cultura/solo constante. Como resultados, o VANT apresentou valores próximos a 96 e 99% de sensibilidade e seletividade, respectivamente, na detecção de plantas daninhas. AKBAR *et al.*, (2019) também utilizaram sensores ultrassom para medir o nível de água num sistema de irrigação para arrozais, que apresentaram erros médios de 0,32cm entre os valores absolutos e os valores medidos pelos sensores.

3. METODOLOGIA

O projeto foi desenvolvido no Laboratório de Instrumentação e Controle da Faculdade de Engenharia Agrícola (LIC/FEAGRI), na cidade de Campinas/SP com as coordenadas 22°49'08.60S 47°03'38.37"W e vento médio de 11 km/h predominante na direção leste. Foram realizados testes de laboratório, em bancada, para que fosse possível avaliar o comportamento individual das frentes de pesquisa e a identificação de estresse hídrico.

Optou-se por aplicar os testes na cultura de Rúcula (*Eruca sativa Miller*) devido à distribuição homogênea no formato das folhas. A área de cultivo da bancada de testes tem 0,75m x 1,5m x 0,25m, onde foi utilizado o espaçamento de 0,20m entre linhas e 0,05m entre plantas de acordo com as recomendações de FREITAS *et al.*, (2009). Foi usada terra vegetal como meio de cultivo das plantas.

A Figura 5 representa o fluxograma do processo, mostrando todas as fases que compreendem as etapas. As etapas na Figura 5, foram separadas em blocos, a saber: (i) Dados de Temperatura e Umidade Relativa, (ii) Processamento de imagem, (iii) Imagem Térmica, (iv) Equação NWSB, (v) Umidade do Solo. Cada etapa do fluxograma é descrita detalhadamente a seguir.




Figura 5 - Fluxograma do processo para a detecção do estresse hídrico através do CWSI.

3.1.Descrição dos Sensores e Equipamentos utilizados

A bancada foi instrumentada com os sensores infravermelho, ultrassom, de temperatura e umidade e com a câmera ótica. A Figura 6 mostra a configuração do sistema em que os testes foram realizados, com os sensores e os dispositivos embarcados para o processamento dos dados.




Figura 6 - Esquematização do teste em bancada, mostrando a disposição dos conjuntos de sensores para a detecção do estresse hídrico através do CWSI.

O sensor ultrassom digital utilizado foi o modelo HC-SR04 da ElecFreaks, com faixa de operação entre 2mm e 4,00m, precisão de ± 3 mm, foi utilizado para medir a altura do sistema. A distância para medição das temperaturas recomendada é de 1m acima das folhas ((JESÚS *et al.*, 2015; JIMÉNEZ-BELLO *et al.*, 2011; SILVA *et al.*, 2018; TESTI *et al.*, 2008), porém após uma avaliação do comportamento do sensor IR em relação à altura de medição e ao porte da cultura, optou-se por utilizar a distância de 0,05m.

O sensor IR (Figura 7a) utilizado neste experimento foi o MLX90614 (MLX90614-ESF-BAA), da fabricante Melexis, com faixa de operação configurável entre -70 e 180°C, precisão de $\pm 0,5^\circ\text{C}$ e um campo de visão (FOV) cônico de 90°. A emissividade do sensor MLX90614 é regulável entre 0,00 e 1,00, no experimento, o equipamento foi regulado para que

pudesse capturar a emissividade de folhas vegetais igual a 0,98 (JONES *et al.*, 2018; MONTEITH, JOHN L.; UNSWORTH, 2013).

De acordo com o fabricante, a temperatura medida pelo sensor IR, também chamada de Temperatura do Objeto (T_o) é a média de todas as temperaturas dentro da área de leitura. Como o FOV é cônico, sua redução diminuirá a área de leitura e, portanto, apresentará uma leitura mais precisa, uma vez que ambas são diretamente proporcionais. Buscando diminuir o FOV, utilizou-se um aparato metálico no sensor (Figura 7b) que colima o feixe de infravermelho. Dado que a área de leitura do sensor IR é função da altura do conjunto de sensores, esta deve ser mantida constante.




Figura 7 - Sensor MLX90614 (a)sem aparato (b)com aparato metálico.

Para medir a T_A e UR, utilizou-se o sensor AM2302, do fabricante Aosong, com faixa de operação entre -40 a 80°C e 0 a 100 UR, com precisão de $\pm 0,5^\circ\text{C}$ e $\pm 2\%$ UR). Este sensor é amplamente usado pela sua precisão e sua facilidade de comunicação com dispositivos embarcados (FLORES *et al.*, 2017; MESAS-CARRASCOSA *et al.*, 2015; MUANGPRATHUB *et al.*, 2019).

A câmera IR para a obtenção das imagens térmicas utilizada foi a FLIR B400, do fabricante FLIR Systems, calibrada e certificada em outubro/2019, com faixa de operação entre -100 e 350°C , sensibilidade de $0,05^\circ\text{C}$ a 30°C e 2% de precisão, assim como faixa de detecção de ondas entre $8 - 14\mu\text{m}$.

Para a obtenção das imagens RGB, foi utilizada a câmera digital do Iphone 7 (Apple Inc.) com as especificações: Sensor de 12MP, $f/1.8$, 28mm , $1/3''$ e conjunto ótico de estabilização de imagens.

Para monitorar a umidade do solo, foram usados sensores EC-5, da Decagon Devices, cujo princípio de medição é o Conteúdo Volumétrico de Água (CVA) e fazem leituras de 0% até a saturação de água no solo, por volta de 60% , com precisão de $\pm 0,02\text{m}^3/\text{m}^3$.

3.2. Mapa de Temperaturas Foliares (MTF)

A diferença entre as temperaturas foliar (T_F) e ambiente (T_A) é um dos parâmetros utilizados na equação do CWSI. Para gerar um Mapa de Temperaturas Foliares, onde somente as plantas fossem consideradas, foi necessário fazer o cruzamento de informações do mapa térmico gerado pelo sensor IR com a imagem de plantas segmentadas. Pontos onde o processamento dessa imagem identificou como solo foram tiveram suas informações de temperaturas zeradas, assim como onde foram identificadas plantas, as informações foram mantidas.

3.2.1. Mapa Térmico de Solo/Planta

Foram usados motores de passo para movimentar o conjunto tridimensionalmente pelos eixos X, Y e Z, que por meio da utilização de coordenadas locais, percorria toda a área de testes realizando diariamente uma pré-varredura com altura fixa de 0,5m acima do nível do solo para determinar, através do sensor ultrassom, qual era a faixa de altura das plantas. De acordo com a altura máxima encontrada, a altura do conjunto era ajustada para que a leitura do sensor de infravermelho ficasse 0,05m acima no nível das plantas. A distância do conjunto foi aferida constantemente com o auxílio de uma trena manual.

Uma varredura foi realizada diariamente fazendo leituras estáticas das informações dos sensores IR e AM2302, durante todo o período da cultura, sempre às 12:00h, por ser um horário com a melhor correlação entre CWSI e potencial de água das folhas (Ψ_L) (BELLVERT *et al.*, 2013).

Foi estabelecido um pixel com tamanho de 20x20mm onde, em cada ponto, eram conhecidas as coordenadas X, Y e os valores de T_O , T_A e UR. Vale ressaltar que as informações eram lidas em pontos com planta e solo, somente planta ou somente solo, de acordo com sua localização. Com as informações de T_O foi possível gerar um Mapa térmico de Solo/Planta de toda a área experimental, já os outros dois parâmetros lidos foram utilizados para o cálculo do CWSI.

3.2.2. Processamento de Imagens

Para a identificação e segmentação das folhas e do solo foram aplicadas técnicas de visão computacional. Os testes foram realizados com a câmera RGB e um computador que

possui processador Intel Core i5 de 8ª geração com 3,90 Ghz, 12GB de memória RAM e placa de vídeo NVIDIA GEFORCE MX 130 de 2GB.

O algoritmo para o processamento das imagens foi construído em linguagem PYTHON e usou as bibliotecas: *Open-CV* para os comandos relacionados às manipulações das imagens; *Numpy* para a realização das operações matemáticas envolvidas no processo e *Pandas* para agrupar e organizar os dados de saída (*outputs*) de cada modelo.

Para a segmentação da imagens utilizou-se 10 modelos com melhor performance de classificação apresentados por PERISSINI (2018), conforme mostrado na Tabela 2. O equacionamento e a limiarização de cada modelo são apresentados no apêndice 1.

Tabela 2 - Modelos classificados por PERISSINI (2018)

ID	Abordagem
1	HSV intervalo
2	HSV (t)
3	CrCbCg (Cg)
4	CrCbCg (Excess Green)
5	YCrCb (Cr+Cb)
6	Excess Green (RGB)
7	$L*u*v*(u*-v*)$
8	$L*a*b*(b*-a*)$
9	NDI manual
10	L1L2L3 (L3)

A avaliação das abordagens foi feita através do *F-score* (Equação 3), definido por PERISSINI (2018) como a média harmônica entre a Precisão (Equação 4), quantidade de classificações corretas positivas em relação ao total de classificações positivas e Sensibilidade (Equação 5), quantidade de classificações positivas corretas em relação aos pixels pertencentes às plantas. De uma forma robusta, essa métrica quantifica a classificação das imagens, entre a ausência de Verdadeiros Positivos (VP) como 0 e uma classificação perfeita como 1.

$$Fscore = 2 * \frac{Precisão * Sensibilidade}{Precisão + Sensibilidade} = \frac{2VP}{2VP + FP + FN} \quad [\text{Equação 3}]$$

$$Precisão = \frac{VP}{VP + FP} \quad [\text{Equação 4}]$$

$$\text{Sensibilidade} = \frac{VP}{VP+FN} \quad [\text{Equação 5}]$$

$$\text{Erro total} = \frac{FP+FN}{VP+VN+FP+FN} \quad [\text{Equação 6}]$$

$$\text{Acurácia} = \frac{VP+VN}{VP+VN+FP+FN} \quad [\text{Equação 7}]$$

Onde VN (Verdadeiro Negativo) são as classificações negativas verdadeiras, FP (Falso Positivo) são as classificações positivas falsas e FN (Falso Negativo) são as classificações negativas falsas. Ainda de acordo com PERISSINI (2018), o erro total (Equação 6) significa a proporção de avaliações incorretas no total de avaliações realizadas e por sua vez, a acurácia (Equação 7) são as avaliações corretas no total realizado.

As imagens *target*, que serviram de referência para determinar se a classificação está ou não correta foram manualmente classificadas. A binarização de cada imagem foi feita através da média entre 10 pixels selecionados com os valores RGB das plantas. Foram considerados como planta (valor 1) os pixels que estavam dentro da faixa de valores entre *Média ± desvio padrão*, de forma que pixels contendo solo receberam valor 0.

Ao aplicar cada modelo em 15 imagens geradas ao longo do ciclo da cultura, período médio de 30 dias (TRANI; FORNASIER; LISBÃO, 1992), foram obtidas 150 imagens binárias. Dessa forma, foram obtidos os valores de *F-score*, de acurácia e também de tempo de processamento. O tempo de leitura de cada imagem não foi considerado, por ser o mesmo para todas as imagens analisadas. A partir desses parâmetros foram calculadas as respectivas precisões da classificação de cada um dos modelos, dadas as variações nas imagens, ou seja, o quão consistente seria o resultado apresentado por cada uma das 10 abordagens de classificação de imagens avaliadas.

A estatística descritiva clássica foi usada na avaliação dos modelos, e o qual apresentou as melhores métricas foi usado para o processamento das imagens obtidas durante o ciclo da planta, cuja saída foi uma imagem com a segmentação das plantas e as coordenadas locais de interesse.

3.2.3. Validação do MTF

A sobreposição da imagem segmentada no mapa térmico de Solo/Planta gerou então o Mapa de Temperaturas Foliaves, usadas para o cálculo do CWSI. Sua avaliação foi feita pela comparação com a imagem gerada pela câmera IR, que foi posicionada perpendicularmente ao solo e de acordo com a literatura, a distância de medição também foi de 1m. As imagens térmicas obtidas pela câmera IR foram tratadas pelo software próprio do fabricante. A validação foi feita analisando-se pixel a pixel, pela diferença entre as temperaturas lidas pelo sensor IR ($S_{x,y}$) e pela câmera ($C_{x,y}$), como mostra a Equação 8 e o erro médio geral calculado pela Equação 9, onde n é o número de pixels dos mapas gerados. O erro médio padrão também foi calculado.

$$Erro_{x,y} = \frac{S_{x,y} - C_{x,y}}{C_{x,y}} \quad [\text{Equação 8}]$$

$$Erro\ médio\ geral = \frac{\sum erro_{x,y}}{n} \quad [\text{Equação 9}]$$

3.3. Parametrização da *Non Water-Stressed Baseline* (NWSB)

A equação NWSB foi parametrizada com os dados obtidos em uma segunda bancada experimental, de características iguais às da bancada principal, como mesmas dimensões, tipo de solo, quantidade e espaçamento de plantas. As duas bancadas estavam localizadas no mesmo ambiente, possibilitando assim o compartilhamento de dados e condições.

Utilizou-se um segundo sensor AM2302 para fazer as leituras de T_A e UR, e outro sensor IR, disposto em pontos fixos, para ler a T_F das plantas. É importante destacar que como este sensor não fazia uma varredura e sim leituras fixas, foi posicionado de maneira que somente as folhas da Rúcula estivessem dentro da área de leituras do sensor, como fizeram BELLVERT *et al.*, (2013).

Foram realizadas medições com um intervalo de 10 minutos num período de 30 dias, considerando o ciclo médio da rúcula (TRANI; FORNASIER; LISBÃO, 1992). Para a parametrização da equação, além de serem considerados dois ciclos de plantio, foi necessário calcular o déficit de pressão de vapor (VPD), através dos valores de T_A e UR lidos pelo sensor

AM2302. O VPD foi calculado por meio da Equação 10.

$$VPD = (1 - UR) * 0,6108. 10^{\frac{7,5T_A}{273,3+T_A}} \quad [\text{Equação 10}]$$

Ao correlacionar os valores de $(T_F - T_A)$ e VPD, a equação NWSB corresponde ao modelo linearizado da nuvem de pontos gerada. Esta equação foi usada para o cálculo do estresse hídrico das plantas na bancada principal de testes.

Seguindo a metodologia de TESTI *et al.*, (2008), $(T_F - T_A)$ e o VPD poderiam ser correlacionadas de acordo com o horário das medições, já que variam ao longo do dia. Porém para este estudo, optou-se por utilizar uma correlação simplificada e apenas um valor médio diário, uma vez que a varredura dos pontos e o cálculo do CWSI foram feitas apenas uma vez ao dia. As curvas obtidas por estas correlações forneceram as equações NWSB com a aproximação necessária.

O limite inferior $(T_F - T_A)_{LL}$ do CWSI foi calculado pela equação da NWSB, com os valores de VPD do ambiente no momento da leitura durante a varredura diária dos sensores, podendo ser compreendido como o coeficiente linear da equação obtida. O cálculo do limite superior $(T_F - T_A)_{UL}$ seguiu a metodologia usada por IDSO, S. B. *et al.*, (1981), que utiliza um VPD potencial para simular o acréscimo de $(T_F - T_A)$ quando o VPD é zero na temperatura do ambiente, gerando um novo valor de VPD que deve ser utilizado na Equação da NWSB, resultando no limite máximo da diferença de temperaturas.

3.4.Cálculo do CWSI

Com todos os parâmetros definidos, foi possível calcular o CWSI pela Equação 11, encontrando quantitativamente o grau de estresse da planta no momento da varredura.

$$CWSI = \frac{(T_F - T_A) - (T_F - T_A)_{LL}}{(T_F - T_A)_{UL} - (T_F - T_A)_{LL}} \quad [\text{Equação 11}]$$

O valor de referência do CWSI para plantas, em geral, que não estão sob estresse hídrico, deve ser igual ou inferior a 0,2 (BELLVERT *et al.*, 2013; KACIRA; LING; SHORT, 2002; TANDA; CHIARABINI, 2019).

O mapa de estresse hídrico gerado pelo CWSI foi validado através do monitoramento de umidade do solo com os sensores EC-5 (Figura 8). A bancada experimental

foi separada em três tratamentos, onde cada um deles foi submetido a um regime de irrigação próprio, com diferentes condições hídricas.




Figura 8 - Distribuição dos sensores de umidade do solo dispostos no centro da entrelinha de cada tratamento da área experimental.

Os sensores de umidade detectaram a capacidade de campo (CC) do solo e foi aplicada uma diferença entre a CC e a umidade de ativação da irrigação, sendo 85% CC, 75% CC e 55%CC os tratamentos 1, 2 e 3, respectivamente. Como a disponibilidade de água para as plantas de cada tratamento era diferente, o mapa deve ser capaz de identificar faixas de estresse hídrico compatíveis com cada tratamento.

A rotina de leitura dos sensores garantiu um intervalo de 20 minutos a cada medição e, dessa forma, o sistema irrigava individualmente cada tratamento quando os sensores indicassem umidades 15, 25 e 45% menores que a CC de cada tratamento, respectivamente. A quantidade de irrigação foi 0,7 litros, distribuídos pela área de cada tratamento, e mantida fixa durante todo o ciclo de cultura da planta. Também foram registrados os eventos de irrigação para serem relacionados aos dados de umidade.

Por não apresentarem um padrão normal, tanto o CWSI quanto a umidade do solo foram estatisticamente avaliados pelo gráfico de Média Móvel Exponencialmente Ponderada (MMEP), como feito por (ALBIERO *et al.*, 2012).

4. RESULTADOS E DISCUSSÃO

4.1. Mapa de Temperaturas Foliares

4.1.1. Altura das plantas e do conjunto

De acordo com o crescimento das plantas, as leituras do sensor de ultrassom são mostradas na Figura 9, onde podemos acompanhar o aumento a altura do conjunto ao longo do tempo.




Figura 9 - Altura do sistema ao longo do ciclo da cultura.

É possível observar que o crescimento das plantas nos 15 primeiros dias após o plantio das mudas acontece num ritmo mais lento e vai aumentando de acordo com o passar dos dias. O acúmulo de massa seca da rúcula também segue esse comportamento, sendo essa primeira fase da planta responsável pelo acúmulo de apenas 30% da massa seca total da planta em seu estágio de colheita (GRANGEIRO *et al.*, 2011). O espaçamento utilizado de 200x50mm também se mostrou adequado, possibilitando o crescimento das plantas, como demonstrado por PEREIRA *et al.*, (2014). Os autores avaliaram diferentes espaçamentos e concluíram que 50mm de distância entre plantas proporcionou a maior altura destas, mas ao mesmo tempo, utilizar o espaçamento de 100mm entre fileiras proporcionaria uma maior área foliar das plantas, parâmetro que afetaria o processamento das imagens deste trabalho.

Estudos da literatura mostram que o porte da cultura é um fator que influencia diretamente na distância utilizada entre a planta e o sensor de temperatura. Em plantas de maior porte como macieiras, pereiras e oliveiras, a distancia costuma ser próxima de 3m (JESÚS *et al.*, 2015; JIMÉNEZ-BELLO *et al.*, 2011; TESTI *et al.*, 2008), já em culturas de médio porte como milho, tomate, berinjela e viticultura são feitas medições próximas à 1m da planta (ÇOLAK *et al.*, 2015; DA SILVA *et al.*, 2018; FATTAHI *et al.*, 2018; GHAEMI *et al.*, 2016).

Porém utilizar essas distâncias neste projeto faria com que a leitura do sensor IR não fosse precisa, uma vez que o porte da cultura é pequeno e a área de leitura do sensor seria maior que a de uma planta. A distancia de 0,05m entre a planta e o sensor de temperatura também foi usada para as culturas de alface (ADEYEMI *et al.*, 2018), do açafrão (SHIRMOHAMMADI; KAMGRA; SEPASKHAH, 2006), da pimenta do reino (CAMOGLU; DEMIREL; GENC, 2018) e os resultados obtidos por esses trabalhos mostraram que as leituras de temperatura à essa distancia foram adequadas para o monitoramento de estresse hídrico das plantas.

4.1.2. Mapa Térmico de Solo/Planta

Como o FOV do sensor IR utilizado é direcional e depende da altura do conjunto, a distância constante de medição entre planta e sensores fez com que as perdas de informações nas leituras fossem diminuídas e cada “pixel” de informação no mapa gerado tivesse o tamanho de 20x20 mm. De acordo com o fabricante deste sensor, que possui uma versão do MLX90614 com FOV de 14°, o que diferencia a abertura do FOV destes sensores é um aparato metálico que concentra o feixe de luz. A utilização do aparato metálico para colimar os feixes emitidos pelo sensor IR se mostrou válida, como mostra a Figura 10.




Figura 10 - Mapa de Temperaturas gerados pelo sensor IR (a) sem aparato e (b) com aparato nos tratamentos 1,2 e 3 da área experimental, onde o CVA de cada tratamento foi CC-5%, CC-10% e CC-15%, respectivamente.

Nos mapas acima, as temperaturas máximas e mínimas foram normalizadas para que a diferença de horários em que foram medidas não interferisse no resultado. A perda de informações é causada pela maior área de leitura do sensor, cujo FOV é de 90° sem a utilização do aparato, uma vez que algumas folhas da rúcula podem ser menores que essa área, fazendo com que a temperatura da folha entre apenas como parte da média calculada. Verificou-se também que apesar de apresentarem leituras próximas, o comportamento do mapa gerado utilizando o aparato metálico apresentou maior semelhança com a disposição real da cultura.

As varreduras realizadas foram capazes de gerar pontos com coordenadas locais e os valores de T_O , T_A e UR, porém estes últimos dois servem apenas para o cálculo do CWSI. Na Figura 11 podemos ver um dos mapas gerados, no 25º dia após o plantio (DAP), com um conjunto completo de pontos. Uma vez que as varreduras eram diárias, foi obtido um mapa térmico por dia.




Figura 11- Mapa Térmico da área experimental, mostrando pontos de solo, planta ou a combinação destes. O mapa foi gerado no 25DAP, fase final da cultura.

É possível observar que as temperaturas observadas variam entre 19,5°C e 22,5°C, porém é importante ressaltar que neste mapa foram lidos pontos sem nenhuma segmentação de plantas, ou seja, estão presentes leituras de pixels contendo somente solo, somente planta e a junção dos dois. Pontos que continham apenas solo apresentaram temperaturas maiores do que pontos com solo e planta ou apenas planta. Para que o cálculo do CWSI seja válido, deve-se ter apenas as temperaturas das folhas, portanto, a etapa do processamento das imagens foi realizada em sequência.

4.1.3. Processamento de Imagens

As 15 imagens foram processadas e para cada uma delas foram geradas 10 novas imagens *outputs*, ou seja, imagens binárias com a segmentação das plantas. Como as imagens foram capturadas em diferentes fases da cultura (Figura 12), foi possível observar diferentes formatos e tamanhos das plantas e com isso, avaliar a robustez dos métodos estudados.



Figura 12- Imagens da cultura em diferentes estágios de desenvolvimento, utilizadas na avaliação dos métodos de processamento.

Além da clara diferença entre a densidade de plantas na área experimental ao longo do desenvolvimento da cultura, as diferenças na coloração do solo causadas pela umidade do solo são fatores que podem gerar perturbações e afetar os resultados gerados no processamento das imagens. Vale ressaltar que, para esta etapa, não houve divisão entre os tratamentos.

Ao classificar manualmente as imagens como referência na avaliação dos modelos, foram geradas imagens segmentadas (Figura 13a) e posteriormente os pixels com plantas receberam valor 1 (Figura 13b). Aplicando os conjuntos de equações de cada método avaliado, foi possível obter as métricas de cada um deles (Tabela 3), considerando as 15 imagens como repetições.




Figura 13- Imagens *Target* utilizadas como referência para a avaliação das abordagens, onde (a) os pixels foram segmentados dentro da média dos 10 pixels selecionados e (b) receberam valor igual a 1.

Os processos de segmentação e classificação de plantas se mostraram complexos e fortemente dependentes das condições em que a imagem foi gerada. Além disso, o ambiente agrícola costuma apresentar diversas heterogeneidades, porém a iluminação foi o parâmetro que mais afetou a qualidade das imagens.

As segmentações baseadas em cores foram as mais recomendadas, pelos bons resultados apresentados e a menor complexidade em processamento, corroborando os resultados obtidos por HERNÁNDEZ-HERNÁNDEZ *et al.*, (2016), PRATAMA *et al.*, (2020) e SRIWASTWA *et al.*, (2018).

Tabela 3 - Desempenho de segmentação dos métodos avaliados para o processamento de imagens. A estatística descritiva das métricas utilizadas para a avaliação dos modelos é mostrada no APÊNDICE 2.

ID	Abordagem	Precisão [%]	Sensibilidade [%]	F-score [%]	Erro Padrão [%]	Erro Total [%]	Acurácia [%]	Erro Padrão [%]	Tempo de Processamento [s]
1	HSV Intervalo	72,13	94,45	81,59	0,97%	17,49	82,51	1,44%	6,97 ± 0,41
2	HSV(t)	71,64	94,48	81,32	0,94%	17,48	82,52	1,43%	6,95 ± 0,43
3	CrCbCb(Cg)	82,01	91,52	86,22	0,95%	11,55	88,45	1,11%	5,10 ± 0,31
4	CrCbCb(ExG)	86,41	88,00	86,95	0,68%	10,11	89,89	0,73%	5,10 ± 0,31
5	YCrCb(Cr+Cb)	89,48	77,95	83,06	1,88%	11,48	88,52	0,58%	5,16 ± 0,3
6	ExG (RGB)	88,79	84,83	86,54	0,66%	9,96	90,04	0,57%	1,50 ± 0,03
7	L*u*v*(u*-v*)	78,57	93,41	85,27	0,74%	12,36	87,64	0,82%	17,29 ± 0,85
8	L*a*b*(b*-a*)	79,03	92,44	85,11	0,79%	12,46	87,54	0,89%	9,42 ± 0,53
9	NDI	73,81	78,40	74,16	4,61%	18,93	81,07	2,39%	0,86 ± 0,14
10	L1L2L3(L3)	68,20	94,89	79,12	1,10%	20,23	79,77	1,98%	1,93 ± 0,32

Ao avaliar o ID6, *Excess Green* em RGB, observou-se que este foi o método que apresentou o melhor conjunto de resultados, apresentando o segundo maior F-score e a maior acurácia, por isso, esse foi o método escolhido para ser utilizado neste trabalho. Seu tempo de processamento médio foi de 1,5 segundos, com uma baixa variação desses valores, indicando menor complexidade de processamento que os outros métodos avaliados. Apesar deste apresentar valores relativamente baixos de sensibilidade, a precisão do método, ou seja, a quantidade de pixels classificados como plantas que realmente eram plantas fez com que o erro total do método fosse o mais baixo encontrado. A performance deste método corroborou os resultados de PERISSINI (2018), que também apontaram o *Excess Green* em RGB com os melhores valores de F-score em suas avaliações, porém o tempo de processamento encontrado pelo autor foi maior que o deste estudo. Essa diferença se dá pelas diferentes condições de ambiente no momento em que as imagens foram capturadas e mostra a complexidade do processamento de imagens, uma vez que técnicas e abordagens semelhantes podem produzir resultados distintos.

Tanto o ID1, método considerado como referência por ser amplamente usado, quanto o ID2 apresentaram boa sensibilidade, porém a precisão destes apresentou o segundo valor mais baixo entre os métodos. Isso mostra que esses métodos foram capazes de classificar bem as plantas, porém a presença dos falsos positivos fez com que o número de classificações

de fato corretas diminuísse. As imagens com menores níveis de iluminação afetaram esses métodos de uma forma mais severa. Entretanto, os dois métodos apresentaram valores semelhantes de *F-score* e de acurácia.

Os Ids 3 e 4 não apresentaram os maiores valores de precisão e nem sensibilidade, porém esses foram os métodos com maiores valores de F-score, uma vez que esse leva em consideração uma média harmônica entre as duas métricas. Além disso, o ID4 apresentou menor variação entre as repetições, com um desvio padrão de 2,7%. O tempo de processamentos dos dois métodos foi idêntico, porém é possível observar que o ID3 apresentou um erro total maior que o ID4, revelando que ao usar a cromaticidade da banda G, a ocorrência de falsos positivos é maior.

O ID5, apesar de ser o modelo nos quais os métodos CrCb são derivados, apresentou resultados inferiores a estes. Observou-se a influência do tamanho das plantas nos resultados, gerando suas melhores classificações em imagens com plantas menores, e que a cor do solo, afetada por sua umidade, também influenciou nos resultados, perdendo sensibilidade nas imagens com solo mais seco.

Como os métodos com ID 7 e 8 são baseados nos espaços de cor uniformes, estes apresentaram respostas sensíveis à detecção de plantas, porém se mostraram instáveis em condições de maior luminosidade, fazendo com que a presença de falsos positivos afetasse a precisão dos métodos. Apesar de o $L^*u^*v(u^*-v^*)$ ter apresentado quase metade do tempo de processamento do $L^*u^*v(u^*-v^*)$, ambas as abordagens apresentaram valores elevados quando comparadas às outras abordagens avaliadas. Os erros totais de classificações, por sua vez, resultaram em 12,36% e 12,46% para os IDs 7 e 8, respectivamente.

Mesmo apresentando o menor tempo de processamento entre todos os métodos avaliados, o NDI, representado pelo ID9, apresentou os piores resultados de F-score e de acurácia. Ao observar o desvio padrão dessas métricas, pode-se observar valores altos, revelando uma inconsistência na classificação das imagens. Apesar disso, PERISSINI (2018) avaliou esse método como consistente e apresentando altos valores de F-score, porém seus resultados foram obtidos em condições críticas de sombra e incidência de luz.

O método L1L2L3(L3) foi o mais sensível dos métodos avaliados com 94,89%, porém sua baixa precisão mostra que o número de falsos positivos, ou seja, pontos cuja classificação correta seria solo, mas foram classificados como plantas, fez com que esse método não resultasse em um *F-score* maior que 80%. Além disso, este foi o modelo que apresentou o maior erro total e consequentemente, a menor acurácia das abordagens avaliadas.

A Figura 14 mostra o resultado do processamento de uma mesma imagem através dos 10 métodos avaliados, onde pode-se observar as diferenças entre a segmentação de plantas, com pixels identificados como planta ou não. O ExG(RGB) apresentou as melhores métricas e os métodos que apresentaram os menores valores de F-score e acurácia foram os que apresentaram as piores classificações, fazendo com que houvesse perda de informações ao sobrepor os mapas de segmentação e de temperatura para gerar os mapas de temperaturas foliares.




Figura 14 - Imagens segmentadas geradas por todos os métodos avaliados, utilizando a mesma imagem RGB. O método ExG(RGB) apresentou as melhores métricas e foi usado neste trabalho, enquanto o NDI manual foi o pior método avaliado.

4.1.4. Validação do MTF

Com os resultados do mapa térmico gerado e da segmentação das imagens, foi possível fazer o cruzamento de informações e a sobreposição desses dados gerou um MTF (Figura 15). Para isso, ocorreu a multiplicação pixel a pixel dos pontos do mapa de temperatura por valores 0 ou 1, de acordo com a imagem segmentada do processamento de imagens.




Figura 15 - Mapa de Temperatura Foliares gerado através do cruzamento do mapa de temperaturas da área experimental com a imagem segmenta da cultura- 25DAP

O redimensionamento das imagens foi essencial para a sobreposição dos mapas, uma vez que a imagem RGB possuía originalmente 5000 x 2700 pixels e o mapa de temperaturas gerado possui 61 x 22 pixels, portanto as dimensões finais do MTF são 1280 x 620 pixels.

Podemos observar que os tratamentos apresentaram diferentes faixas de temperaturas foliares, onde o tratamento 3, que foi irrigado somente quando o CVA do solo atingiu 85% da CC, apresentou as maiores T_F se comparado aos tratamentos 1 e 2, irrigados em 95% e 90% da CC, respectivamente. Este comportamento é esperado, uma vez que as condições hídricas de cada um dos tratamentos são diferentes, causando menor quantidade de água disponível para as plantas e consequentemente, diferentes níveis de fechamento estomatal.

A validação do MTF foi feita através da imagem obtida pela câmera térmica (Figura 16a), onde é possível ver que as temperaturas mínimas foram 19,2°C. A imagem gerada excede os limites da área experimental, fazendo com que a faixa superior de valores de temperatura esteja fora da faixa de temperaturas máximas da cultura. Para eliminar a parte da imagem que não corresponde à área de interesse, a imagem de segmentação das plantas também foi sobreposta na imagem térmica, fazendo com que somente os pixels com plantas fossem avaliados.




Figura 16 – Imagem térmica gerada, no 25DAP, pela câmera IR (a) original e (b) redimensionada com a sobreposição da imagem processada para a segmentação das plantas.

O erro médio entre as temperaturas medidas pelo sensor IR e pela câmera foi de -0,1959, ou seja, as temperaturas medidas pelo sensor estavam, na média, 0,2°C abaixo da temperatura medida pela câmera térmica, valor considerado baixo. O erro padrão foi igual a 0,03%. Este sensor é amplamente utilizado em estudos agrícolas, pelo seu baixo custo e os bons resultados apresentados por FISHER e KEBEDE, (2010), GINTSIOUDIS *et al.*, (2020), MARTÍNEZ *et al.*, (2017) e SUDIANTO *et al.*, (2020).

Apesar do erro médio encontrado de 0,2°C estar dentro da precisão fornecida pelo fabricante, de $\pm 0,5^\circ\text{C}$, pode-se observar que a escala de valores obtidos pela câmera térmica apresenta pontos com até 2,5°C de diferença do sensor, isso pode ser explicado pelo redimensionamento dos mapas e imagens, onde a interpolação é feita de forma bi-linearizada e pela diferença na quantidade de pixels originais, o valor dos pixels redimensionados pode ter sido alterado.

4.2. Equação NWSB

A equação foi parametrizada com os valores de $(T_F - T_A)$ e os valores de VPD medidos a cada 10 minutos ao longo de todo o ciclo da cultura na bancada que estava nas mesmas condições que a bancada utilizada para as varreduras. A Figura 17 mostra o monitoramento de T_O , T_A e UR, onde podemos ver que as temperaturas não tiveram grande variação.




Figura 17 - Monitoramento da Temperatura ambiente, de objeto e da Umidade Relativa para a bancada auxiliar na parametrização de NWSB.

Ao avaliar a imagem acima, podemos observar que os valores de temperatura foliar ficaram sempre abaixo das temperaturas ambiente e isso satisfaz a condição de parametrização da equação, que prevê apenas plantas sem estresse hídrico. A correlação entre a diferença de temperaturas e o VPD (Figura 18) resultou na equação $(T_F - T_A) = -0,7824 \times VPD + 0,1025$.




Figura 18- Parametrização da *Non Water-Stressed Baseline* definida para o ambiente protegido (NWSB_P)

Para efeitos de avaliação, também foi parametrizada uma equação considerando um ambiente desprotegido, cujo monitoramento das temperaturas ambiente e foliar e da UR é mostrado na Figura 19.




Figura 19 - Parametrização da *Non Water-Stressed Baseline* definida para o ambiente desprotegido (NWSB_D)

Apesar dos coeficientes angulares de NWSB_D estarem na faixa de valores próximos aos encontrados na literatura para outras culturas (Tabela 4), observou-se que os limites $(T_F - T_A)_{LL}$ e $(T_F - T_A)_{UL}$ calculados não representaram a real relação entre a diferença de temperaturas foliar e ambiente e o VPD, uma vez que a bancada experimental estava em um ambiente de cultivo protegido, sem a presença de fatores como vento, orvalho e variações grandes de temperatura. Já os coeficientes de NWSB_P se mostraram menores que os encontrados em parametrizações de outras culturas.

Tabela 4 - *Non Water-Stressed Baselines* obtidas na literatura para diferentes culturas

Autores	Cultura	NWSB
(IDSO, SHERWOOD B., 1982)	Alface	$Y = -2,96x + 4,18$
(ERDEM <i>et al.</i> , 2006)	Melancia	$Y = -1,20x + 0,47$
(FATTAHI <i>et al.</i> , 2018)	Milho	$Y = -2,81x - 1,35$
(BELLVERT <i>et al.</i> , 2013)	Uva	$Y = -1,71x + 2,54$
(KUMAR, NAVSAL <i>et al.</i> , 2020)	Mostarda	$Y = -1,71x - 0,47$

BERNI *et al.*, (2009) obtiveram como coeficientes angular e linear os valores -0,35 e 2,08, respectivamente e concluíram que um menor valor de coeficiente angular é observado em plantas que possuem uma relação mais dependente com a atmosfera e o clima, como é o caso das oliveiras, que apresentam uma baixa variação de temperaturas para grandes variações do VPD (AGAM *et al.*, 2013). Os autores apontaram o pequeno tamanho das folhas em relação

ao dossel da árvore e ainda que, para diversas culturas, é comum um certo nível de fechamento estomatal quando há aumento da demanda evaporativa da planta.

A velocidade do vento e a radiação solar são dois parâmetros que influenciam diretamente na obtenção dos limites de temperaturas, uma vez que estes alteram o comportamento das plantas em relação à sua transpiração e consequentemente, suas trocas gasosas (JACKSON, R. D. *et al.*, 1981; JACKSON, RAY D.; KUSTAS; CHOUDHURY, 1988; RUD *et al.*, 2014; WANG, XUEZHI *et al.*, 2010b). Isso evidencia que a parametrização da NWSB deve ocorrer nas mesmas condições climatológicas em que o CWSI será calculado (JACKSON, RAY D.; KUSTAS; CHOUDHURY, 1988), para que a normalização das temperaturas não aconteça de forma deslocada, fazendo com que os limites inferior e superior de $(T_F - T_A)$ fiquem fora da faixa real de variação de temperaturas.

IDSO, S B *et al.*, (1984) também afirmaram que o formato e o tamanho das folhas podem afetar os coeficientes angular e linear da NWSB, algo relevante neste trabalho, uma vez que os dados foram coletados a cada 10 minutos ao longo de todo o ciclo da cultura. O estágio de desenvolvimento da planta também afeta esses coeficientes, por diferentes necessidades hídricas (IDSO, SHERWOOD B., 1982).

Na literatura, alguns trabalhos coletaram dados por 2 anos, na cultura de pistache (TESTI *et al.*, 2008), porém além de serem plantas de grande porte, a idade produtiva dessas plantas pode chegar a 25 anos (GILMAN, 2021), ou seja, as variações de físicas das folhas não foram significativas para afetar a regressão de NWSB. Outros trabalhos parametrizaram a equação com dados coletados por apenas 3 dias, em horários específicos (08:30h; 11:30h; 14:30h; 17:30h; 20:00h)(GARCÍA-TEJERO *et al.*, 2018) e foi observado que as variações de temperatura em horários antes das 09:00h e após as 16:00h não apresentam boas relações com o VPD.

A baixa inclinação da reta $NWSB_P$ e a dispersão dos pontos mostram que a Rúcula pode ser uma cultura que apresenta uma pequena faixa de diferenças entre T_F e T_A em relação ao ambiente, corroborando os resultados encontrados por BERNI *et al.*, (2009). Como consequência, o CWSI pode apresentar uma maior sensibilidade em relação às variações de temperaturas, uma vez que a normalização das temperaturas pode ser afetada pelos limites máximos e mínimos encontrados por NWSB.

Através das análises de regressão estatística e de resíduos, mostradas no APÊNDICE 2, o comportamento das equações parametrizadas para os dois ambientes se mostrou adequado, uma vez que não há viés entre as variáveis e a média dos resíduos foi igual a zero.

4.3.CWSI

Ao calcular o CWSI utilizando os valores de temperatura foliar obtidos no MTF, de T_A e UR obtidos pelo sensor AM2302 e os limites da NWSB_P parametrizada para as condições de ambiente protegido, foi possível gerar um mapa de estresse (Figura 20) nos tratamentos da área experimental.




Figura 20 - Mapa de CWSI da área experimental em ambiente protegido gerado para o 25DAP, em varredura realizada as 12:00hr, horário com melhores resultados de leitura.

Conforme previsto, o comportamento da cultura em relação ao ambiente afetou os limites $(T_F - T_A)_{UL}$ e $(T_F - T_A)_{LL}$ obtidos da equação NWSB, fazendo com que o cálculo de CWSI apresentasse valores ligeiramente maiores que 1. Isso indicaria que as plantas estavam sob 100% de estresse hídrico, porém essas características não foram constatadas ao avaliar visualmente o estado das folhas nos pontos que apresentaram esses valores, mostrando que a faixa de normalização das temperaturas estava deslocada em relação às reais temperaturas foliares da cultura. Alguns valores negativos também foram encontrados, indicando que as plantas não estavam sob nenhum estresse hídrico, e indiretamente, isso ocorre quando a resistência de transporte de vapor do dossel (r_a) é menor que a resistência de aerodinâmica do ar (r_c), como afirmado por SILVA e RAO (2005).

O cálculo de CWSI utilizando os limites advindos de NWSB em climas tropicais é afetado pela alta presença de nuvens, uma vez que estas afetam a radiação solar incidente na cultura (ADEYEMI *et al.*, 2018; COSTA, J. MIGUEL; GRANT; CHAVES, 2013), e o fato da bancada experimental estar localizada num ambiente protegido, onde as plantas não recebiam diretamente a radiação solar ao longo de todo o dia, possivelmente afetou a faixa de temperaturas normalizadas. Valores de CWSI menores que 0 e maiores que 1 são relatados nos

trabalhos de SILVA e RAO (2005), HERNÁNDEZ-CLEMENTE *et al.*, (2019) e QUEBRAJO *et al.*, (2018). Como os valores obtidos estavam próximos do limite normalizado pelo índice, foi realizada uma correção para que valores negativos recebessem 0 como seu novo valor e os valores maiores que 1 fossem reduzidos ao limite do CWSI.

Já ao calcular o CWSI utilizando os limites obtidos pela NWSB_D, foi possível identificar que a normalização dos valores de $(T_F - T_A)$ encontrava-se muito deslocada em relação à real faixa de variações de temperatura. O mapa de CWSI da cultura (Figura 21) gerado para o ambiente desprotegido apresentou valores elevados quando comparado ao mapa gerado para o ambiente da bancada experimental. Pode-se observar que as plantas do tratamento 1 apresentaram valores de CWSI próximos a 0,8, enquanto no mapa da Figura 20 seus valores foram quase todos zeros.




Figura 21 - Mapa de CWSI da área experimental em ambiente desprotegido, gerado para o 25DAP. Os limites superior e inferior de NWSB_D não indicaram valores reais de temperatura e o CWSI mínimo calculado foi 0,6, correspondendo à situação sem estresse hídrico.

Apenas para efeitos de avaliação, o método empírico para se encontrar os limites T_{UL} e T_{LL} foi também calculado no 25DAP, seguindo a metodologia de CAMOGLU; DEMIREL; GENÇ, (2018). Uma das folhas foi molhada com água 1 minuto antes da leitura de temperatura, servindo como referência de uma superfície com máxima transpiração e revelando a temperatura mínima que a planta alcançaria, 19,3°C. Já a outra folha, coberta por vaselina cerca de 30 minutos antes da leitura, serviu como uma superfície onde não há transpiração, indicando como 24,2,0°C a máxima temperatura que a planta poderia chegar nas condições climáticas do dia, apresentando $T_A=22,1^\circ\text{C}$ e $UR=47\%$ no horário da medição. O mapa de CWSI gerado (Figura 22) mostra que os valores não ultrapassaram os limites entre 0 e 1 do índice, e que o nível máximo de estresse lido foi de 0,45 enquanto o mapa gerado através de

NWSB_P apresentou valores iguais a 1. Ao mesmo tempo, pode-se observar que no tratamento 1, os valores de CWSI ficaram entre 0,1- 0,3, já na Figura 20, a grande maioria dos pixels identificado como plantas apresentou valores iguais à 0.




Figura 22 - Mapa de CWSI gerado para o 25DAP, utilizado o método empírico para obter as T_{MAX} e T_{MIN} através de superfícies naturais de referência. Uma das folhas foi molhada com água para simular a 100% de transpiração e a outra com vaselina para bloquear totalmente a transpiração foliar.

(BELLVERT *et al.*, 2013) estudaram o sensoriamento térmico remoto para o cálculo do CWSI e o compararam com métodos locais de medição do potencial de água da folha (ψ_L) para a viticultura. Seus resultados confirmaram o consenso existente na literatura que há uma relação direta entre ψ_L e o CWSI, como mostra a Tabela 5. Além disso, os autores concluíram que o valor de 0,2 deveria ser o valor utilizado para definir um regime de irrigação baseado no CWSI.

Tabela 5- Valores dos índices – adaptado de BELVERT et al. (2014)

Nível de Estresse	ψ_L [MPa]	CWSI
Videiras bem irrigadas	$-0,8 \leq \psi_L \leq -0,6$	$CWSI \leq 0,2$
Videiras sob estresse moderado	$-1,0 \leq \psi_L \leq -1,2$	$0,3 \leq CWSI \leq 0,5$
Videiras sob estresse severo	$\psi_L \leq -1,5$	$0,7 \leq CWSI$

Ao correlacionar o CWSI com a produtividade na cultura da berinjela, ÇOLAK *et al.*, (2015) também obtiveram os melhores resultados para valores do índice iguais a 0,2, notando a produtividade cair de 78,7 para 40,9 t ha⁻¹ quando o CWSI aumentou até 0,6. Já para a cultura da melancia, a produtividade dos tratamentos com os índices 0,2 e 0,4 e 0,6 não apresentou diferenças estatísticas, mostrando que a cultura resiste a maiores níveis de estresse hídrico sem prejudicar seu desenvolvimento e portanto, um sistema de irrigação baseado no

CWSI igual a 0,6 poderia apresentar melhor uso de água, reduzindo seu consumo (ERDEM *et al.*, 2006).

Apesar dos valores de CWSI obtidos para o ambiente protegido terem sido normalizados para estarem dentro da faixa de valores definida entre 0 e 1, foi possível observar que seu mapa de CWSI foi capaz de identificar os diferentes níveis de estresse hídrico de cada tratamento. O monitoramento da umidade no solo (Figura 23) através dos sensores EC-5 mostrou, ao longo do ciclo da cultura, que o Tratamento 1 foi o tratamento com a maior disponibilidade de água no solo para as plantas, tendo seu CVA variando entre 97 - 85% da capacidade de campo do meio utilizado. Já o Tratamento 2 apresentou valores de umidade variando entre 84 - 75% da CC e o Tratamento 3, por sua vez, teve seu CVA entre 70 - 50%.




Figura 23 - Monitoramento da Umidade para cada tratamento ao longo do ciclo da cultura, onde os valores de CVA foram normalizados para evitar diferenças de leituras entre os sensores utilizados.

No 25DAP, data em que foram gerados os mapas apresentados neste trabalho, os valores médios de CWSI foram 0,0072, 0,2731 e 0,3840 para os tratamentos 1, 2 e 3 respectivamente, enquanto seus valores de umidade mostraram 91,21%CC, 79,50%CC e 58,80%CC. Ao longo de todo o ciclo da cultura (Figura 24), foi possível observar que os níveis de estresse aumentaram quando a umidade do solo de cada tratamento diminuiu, revelando que o sistema proposto foi capaz de detectar o estresse hídrico causado por diferentes condições hídricas.




Figura 24 - Níveis de estresse hídrico ao longo de todo o ciclo da Rúcula. A umidade do solo foi normalizada pela capacidade de campo de cada tratamento, igualando assim as referências utilizadas para a medição.

Os resultados acima indicam que uma das respostas da planta à redução na disponibilidade de água é o aumento da temperatura foliar, causado pelo fechamento estomatal (JACKSON, R. D. *et al.*, 1981). O CWSI se mostra um bom indicador de estresse hídrico e pode ser usado na definição do manejo de irrigação de plantas individuais ou de áreas com o mesmo tratamento, corroborando os resultados obtidos por BEN-GAL *et al.*, (2009), CIEZKOWSKI *et al.*, (2020), FATTAHI *et al.*, (2018) que definiram manejos de irrigação utilizando um valor limite de CWSI, para diferentes culturas. Esses valores variam de acordo com o estágio de desenvolvimento da cultura (GONTIA; TIWARI, 2008), revelando a importância de acompanhar os níveis de estresse ao longo de todo o ciclo da planta.

Como discutido por ALCHANATIS *et al.*, (2009), a utilização desta metodologia requer a medição de parâmetros simples como as temperaturas da planta, do ar e a umidade relativa, dispensando o uso de instrumentos ou sensores complexos.

Ao analisar os gráficos MMEP (Figura 25), foi possível observar que nenhum dos pontos, selecionados ao longo do ciclo da cultura, estava fora dos limites de controle superior (LSC) e inferior (LIC), indicando a estabilidade do processo e corroborando os resultados obtidos por ALBIERO *et al.*, (2012) e HOLT (2004). Caso algum dos pontos estivesse fora dos

limites, o processo deveria ser considerado instável. As tabelas de cálculo da MMEP estão dispostas no APÊNDICE 2.




Figura 25 -Gráficos da média móvel exponencialmente ponderada do CWSI e do CVA de cada tratamento.

5. CONCLUSÕES

Este trabalho mostrou que é possível utilizar os sensores IR com FOV direcional para medir a temperatura da planta e através da varredura realizada, gerar um mapa térmico.

A utilização do aparato metálico reduziu as perdas de informações nas leituras do sensor IR e juntamente com a segmentação das plantas na imagem RGB, o Mapa de Temperaturas Foliares gerado foi validado pela imagem térmica gerada nos mesmos dias de medição. Apesar da precisão da câmera IR ser relativamente baixa, estas são atualmente o padrão de medições para o cálculo do CWSI, porém os resultados apresentados pelo sensor IR são satisfatórios, estando dentro da precisão fornecida pelo fabricante e apresentando um custo de aquisição muito menor que o da câmera.

O método ExG(RGB), utilizado para a segmentação de imagens RGB, apresentou métricas muito boas de classificação, entre 86-90% de classificações corretas, e seu baixíssimo tempo de processamento revela um processo computacional menos complexo que outros métodos avaliados, reduzindo assim a necessidade de computadores de alta performance e possibilitando, inclusive, o uso de dispositivos embarcados no sistema de irrigação.

A parametrização da NWSB mostrou que a planta responde de formas distintas em condições climatológicas diferentes. Os limites obtidos na equação do ambiente exterior não possibilitaram o cálculo do CWSI, uma vez que estes alteram a normalização de temperaturas e os valores obtidos não se aproximaram com a realidade de estresse hídrico da cultura. Os limites obtidos por NWSB_P, apesar de apresentarem um ligeiro deslocamento na faixa de temperaturas normalizadas, permitiu que o CWSI fosse calculado para a cultura da rúcula de forma normalizada, corrigindo os valores maiores que 1 ou menores que zero.

O monitoramento da umidade do solo comprovou que as condições hídricas de cada tratamento foram diferentes ao longo de todo o ciclo da cultura, e o sistema proposto foi capaz de detectar diferentes valores de CWSI para as variações de umidade de solo. O índice de estresse aumentou conforme a disponibilidade de água no solo foi reduzida, e os gráficos MMEP mostraram a estabilidade do processo.

Os resultados alcançados neste trabalho sugerem e possibilitam estudos futuros para a criação de um sistema de controle baseado no CWSI para definir o manejo de irrigação num sistema automatizado de irrigação, porém é indicado que a parametrização de NWSB seja realizada em diferentes condições ambientais das avaliadas neste, para que o comportamento da cultura em relação ao ambiente seja validado e a normalização das temperaturas para o cálculo do CWSI seja adequada.

6. REFERÊNCIAS

- ABIDIN, Mohamad Shukri Bin Zainal *et al.* Water uptake response of plant in subsurface precision irrigation system. *Engineering in Agriculture, Environment and Food*, v. 6, n. 3, p. 128–134, 2013.
- ABIOYE, Emmanuel Abiodun *et al.* A review on monitoring and advanced control strategies for precision irrigation. *Computers and Electronics in Agriculture*, v. 173, n. August 2019, p. 105441, 2020. Disponível em: <<https://doi.org/10.1016/j.compag.2020.105441>>.
- ADAMALA, Sirisha; RAGHUWANSHI, N. S.; MISHRA, Ashok. Development of Surface Irrigation Systems Design and Evaluation Software (SIDES). *Computers and Electronics in Agriculture*, v. 100, p. 100–109, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.compag.2013.11.004>>.
- ADEYEMI, Olutobi *et al.* Dynamic modelling of the baseline temperatures for computation of the crop water stress index (CWSI) of a greenhouse cultivated lettuce crop. *Computers and Electronics in Agriculture*, v. 153, n. January, p. 102–114, 2018. Disponível em: <<https://doi.org/10.1016/j.compag.2018.08.009>>.
- AGAM, N. *et al.* An insight to the performance of crop water stress index for olive trees. *Agricultural Water Management*, v. 118, p. 79–86, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2012.12.004>>.
- AKBAR, Son Ali *et al.* Irrigation Distribution System for Agriculture using Fuzzy Control and Android-Based Water Monitoring. v. 189, p. 45–49, 2019.
- ALBIERO, Daniel *et al.* Avaliação da distribuição de sementes por uma semeadora de anel interno rotativo utilizando média móvel exponencial. *Revista Ciência Agronômica*, v. 43, n. 1, p. 86–95, 2012.
- ALCHANATIS, V. *et al.* Evaluation of different approaches for estimating and mapping crop water status in cotton with thermal imaging. *Springer Science+Business Media*, 2009.
- ALSALAM, Bilal Hazim Younus *et al.* Autonomous UAV with vision based on-board decision making for remote sensing and precision agriculture. *IEEE Aerospace Conference Proceedings*, 2017.
- ARJAN GIJSENIJ; THEO GEVERS; WEIJER, J Van de. Computational Color Constancy: Survey and Experiments. *IEEE Transactions on Image Processing*, v. 9, n. 9, p. 2475–2489, 2011.
- AURELIANO NETTO, Abdon Francisco *et al.* Segmentation of Rgb Images Using Different Vegetation Indices and Thresholding Methods. *Nativa*, v. 6, n. 4, p. 389, 2018.
- BALLESTER, C.; CASTEL, J.; *et al.* Thermographic measurement of canopy temperature is a

useful tool for predicting water deficit effects on fruit weight in citrus trees. *Agricultural Water Management*, v. 122, p. 1–6, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2013.02.005>>.

BALLESTER, C.; JIMÉNEZ-BELLO, M. A.; *et al.* Usefulness of thermography for plant water stress detection in citrus and persimmon trees. *Agricultural and Forest Meteorology* *jou*, v. 168, p. 120–129, 2013.

BARBOSA DA SILVA, B.; RAMANA RAO, T. V. The CWSI variations of a cotton crop in a semi-arid region of Northeast Brazil. *Journal of Arid Environments*, v. 62, n. 4, p. 649–659, 2005.

BASSOI, Luís Henrique *et al.* Influência de Manejos de irrigação sobre aspectos de Ecofisiologia e de produção da videira cv. Syrah / Paulsen 1103. *Irriga*, v. 16, n. 4, p. 395–402, 2011.

BELLVERT, J. *et al.* Mapping crop water stress index in a ‘Pinot-noir’ vineyard: Comparing ground measurements with thermal remote sensing imagery from an unmanned aerial vehicle. *Precision Agriculture*, v. 15, n. 4, p. 361–376, 2013.

BEN-GAL, Alon *et al.* Evaluating water stress in irrigated olives: Correlation of soil water status, tree water status, and thermal imagery. *Irrigation Science*, v. 27, n. 5, p. 367–376, 2009.

BERNI, J. A.J. *et al.* Mapping canopy conductance and CWSI in olive orchards using high resolution thermal remote sensing imagery. *Remote Sensing of Environment*, v. 113, n. 11, p. 2380–2388, 2009.

CAMOGLU, Gokhan; DEMIREL, Kursad; GENC, Levent. Use of infrared thermography and hyperspectral data to detect effects of water stress on pepper. *Quantitative InfraRed Thermography Journal*, v. 15, n. 1, p. 81–94, 2018. Disponível em: <<http://doi.org/10.1080/17686733.2017.1331008>>.

CATALDO, Andrea *et al.* Controlling the irrigation process in agriculture through elongated TDR-sensing cables. *I2MTC 2017 - 2017 IEEE International Instrumentation and Measurement Technology Conference, Proceedings*, p. 0–5, 2017.

CHANG, Young K. *et al.* A real-time ultrasonic system to measure wild blueberry plant height during harvesting. *Biosystems Engineering*, v. 157, n. 2460289, p. 35–44, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.biosystemseng.2017.02.004>>.

CIEZKOWSKI, Wojciech *et al.* Remotely sensed land surface temperature-based water stress index for wetland habitats. *Remote Sensing*, v. 12, n. 4, 2020.

ÇOLAK, Yeşim Bozkurt *et al.* Evaluation of Crop Water Stress Index (CWSI) for Eggplant under Varying Irrigation Regimes Using Surface and Subsurface Drip Systems. *Agriculture*

and Agricultural Science Procedia, v. 4, p. 372–382, 2015.

COSTA, Corrado *et al.* Shape Analysis of Agricultural Products: A Review of Recent Research Advances and Potential Application to Computer Vision. *Food and Bioprocess Technology*, v. 4, n. 5, p. 673–692, 2011.

COSTA, J. Miguel; GRANT, Olga M.; CHAVES, M. Manuela. Thermography to explore plant-environment interactions. *Journal of Experimental Botany*, v. 64, n. 13, p. 3937–3949, 2013.

DA SILVA, Cícero J. *et al.* Tomato water stress index as a function of irrigation depths. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 22, n. 2, p. 95–100, 2018.

DANTAS, R. T E ROMANA RAO, T.V. *Monitoramento de deficiência hídrica na cultura do milho com o termómetro infravermelho*. *Pesc. agropec. bras.*, Brasília. [S.l: s.n.], 1994

DIAS, Philipe A.; TABB, Amy; MEDEIROS, Henry. Apple flower detection using deep convolutional networks. *Computers in Industry*, v. 99, p. 17–28, 2018. Disponível em: <<https://doi.org/10.1016/j.compind.2018.03.010>>.

EID, Diana *et al.* Impact of warm vertical compaction on the sealing ability of calcium silicate-based sealers: A confocal microscopic evaluation. *Materials*, v. 14, n. 2, p. 1–8, 2021.

ERDEM, Yesim *et al.* Irrigation Scheduling for Watermelon With Crop Water Stress Index (Cwsi). *Journal of Central European Agriculture*, v. 6, n. 4, p. 449–460, 2006.

FATTAHI, K. *et al.* Scheduling Maize irrigation based on crop water stress index (CWSI). *Applied Ecology and Environmental Research*, v. 16, n. 6, p. 7535–7549, 2018.

FERNANDES, Edemo João. Determinação Do Índice De Estresse Hídrico Em Cultura Do Feijoeiro Com Termômetro De Infravermelho. *Irriga*, v. 15, n. 3, p. 248–257, 2010.

FISHER, Daniel K.; KEBEDE, Hirut. A low-cost microcontroller-based system to monitor crop temperature and water status. *Computers and Electronics in Agriculture*, v. 74, n. 1, p. 168–173, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.compag.2010.07.006>>.

FLORES, Kristoffer O. *et al.* Precision agriculture monitoring system using wireless sensor network and Raspberry Pi local server. *IEEE Region 10 Annual International Conference, Proceedings/TENCON*, p. 3018–3021, 2017.

FREITAS, Carlos De *et al.* Desempenho agrônômico de rúcula sob diferentes espaçamentos e Agronomic performance of rocket under different spacing and planting times Material e métodos Dois experimentos foram conduzidos na horta do. *Revista Ciência Agronômica*, v. 40, n. 1806–6690, p. 449–454, 2009.

GALIOTO, Francesco; RAGGI, Meri; VIAGGI, Davide. Assessing the potential economic viability of precision irrigation: A theoretical analysis and pilot empirical evaluation. *Water*

(Switzerland), v. 9, n. 12, 2017.

GARCÍA-MATEOS, G. *et al.* Study and comparison of color models for automatic image analysis in irrigation management applications. *Agricultural Water Management*, v. 151, p. 158–166, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2014.08.010>>.

GARCÍA-TEJERO, I. F. *et al.* Thermal imaging at plant level to assess the crop-water status in almond trees (cv. Guara) under deficit irrigation strategies. *Agricultural Water Management*, v. 208, n. June, p. 176–186, 2018.

GERARD, France *et al.* Natural resource in southern african drylands: determining spatial availability and variability using atsr2 time series. *Series in Remote Sensing - Analysis of Multi-Temporal Remote Sensing Images*, p. 225–232, 2002.

GEVERS, T.; SMEULDERS, A. W.M. Color based object recognition. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, v. 1310, n. December 1997, p. 319–326, 1997.

GHAEMI, A *et al.* Determining cws_i to estimate eggplant evapotranspiration and yield under greenhouse and outdoor conditions. *Iran Agricultural Research*, v. 34, n. 2, p. 49–60, 2016.

GILMAN, Kory L. *Pistachio Yields and Nut Quality Determination and the Relationship Between Soil Characteristics*. 2021. California State University, 2021.

GINTSIOUDIS, Ippolitos *et al.* Diurnal variations in leaf – Air temperature and vapor pressure deficit of sunlit and shaded kenaf leaves. *CEUR Workshop Proceedings*, v. 2761, p. 574–579, 2020.

GITELSON, Anatoly A.; KAUFMAN, Yoram J.; MERZLYAK, Mark N. Use of a green channel in remote sensing of global vegetation from EOS- MODIS. *Remote Sensing of Environment*, v. 58, n. 3, p. 289–298, 1996.

GONTIA, N. K.; TIWARI, K. N. Development of crop water stress index of wheat crop for scheduling irrigation using infrared thermometry. *Agricultural Water Management*, v. 95, n. 10, p. 1144–1152, 2008.

GRANGEIRO, Leilson C. *et al.* Crescimento e acúmulo de nutrientes em coentro e rúcula. *Revista Brasileira de Ciencias Agrarias*, v. 6, n. 1, p. 11–16, 2011.

GUERRERO, J. M. *et al.* Support Vector Machines for crop/weeds identification in maize fields. *Expert Systems with Applications*, v. 39, n. 12, p. 11149–11155, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2012.03.040>>.

HERNÁNDEZ-CLEMENTE, R. *et al.* Early Diagnosis of Vegetation Health From High-Resolution Hyperspectral and Thermal Imagery: Lessons Learned From Empirical Relationships and Radiative Transfer Modelling. *Current Forestry Reports*, v. 5, n. 3, p. 169–

183, 2019.

HERNÁNDEZ-HERNÁNDEZ, J. L. *et al.* Optimal color space selection method for plant/soil segmentation in agriculture. *Computers and Electronics in Agriculture*, v. 122, p. 124–132, 2016.

HOLT, Charles C. Forecasting seasonals and trends by exponentially weighted moving averages. *International Journal of Forecasting*, v. 20, n. 1, p. 5–10, 2004.

HORTON, Ryan *et al.* Peach Flower Monitoring Using Aerial Multispectral Imaging.pdf. *Journal of Imaging*, v. 3, n. 1, 2017.

IDSO, S. B. *et al.* Normalizing the stress-degree-day parameter for environmental variability. *Agricultural Meteorology*, v. 24, n. C, p. 45–55, 1981.

IDSO, S B *et al.* On the stability of non-water-stressed baselines. *Agricultural and Forest Meteorology*, v. 32, p. 177–182, 1984.

IDSO, Sherwood B. Non-water-stressed baselines: A key to measuring and interpreting plant water stress. *Agricultural Meteorology*, v. 27, n. 1–2, p. 59–70, 1982.

JACKSON, R. D. *et al.* Canopy temperature as a crop water stress indicator. *Water Resources Research*, v. 17, n. 4, p. 1133–1138, 1981.

JACKSON, Ray D. *Canopy Temperature and Crop Water Stress*. [S.l.]: ACADEMIC PRESS, INC., 1982. v. 1. Disponível em: <<http://dx.doi.org/10.1016/B978-0-12-024301-3.50009-5>>.

JACKSON, Ray D.; KUSTAS, William P.; CHOUDHURY, Bhaskar J. A reexamination of the crop water stress index. *Irrigation Science*, v. 9, n. 4, p. 309–317, 1988.

JAFARI, A.; BAKHSHIPOUR, A.; HEMMATIAN, R. Integration of Color Features and Artificial Neural Networks for In-field Recognition of Saffron Flower. *Iran Agricultural Research*, v. 33, n. 1, p. 1–14, 2014.

JESÚS, Asdrúbal *et al.* Determinação do índice de estresse hídrico em tomateiros cereja (*Lycopersicum Solanum* var. *cerasiforme*.) com câmara infravermelha. *Revista Brasileira de Agricultura Irrigada*, v. 7679, n. 1982, p. 218–224, 2015.

JHA, Prakash Kumar; KUMAR, Soora Naresh; INES, Amor V.M. Responses of Soybean to Water Stress and Supplemental Irrigation in Upper Indo-Gangetic Plain: Field Experiment and Modeling Approach. *Field Crops Research*, v. 219, n. January, p. 76–86, 2018. Disponível em: <<https://doi.org/10.1016/j.fcr.2018.01.029>>.

JIANG, Guoquan; WANG, Zhiheng; LIU, Hongmin. Automatic detection of crop rows based on multi-ROIs. *Expert Systems with Applications*, v. 42, n. 5, p. 2429–2441, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2014.10.033>>.

JIMÉNEZ-BELLO, M. A. *et al.* Development and validation of an automatic thermal imaging

- process for assessing plant water status. *Agricultural Water Management*, v. 98, n. 10, p. 1497–1504, 2011.
- JONES, Hamlyn G. *et al.* A practical method using a network of fixed infrared sensors for estimating crop canopy conductance and evaporation rate. *Biosystems Engineering*, v. 165, p. 59–69, 2018. Disponível em: <<https://doi.org/10.1016/j.biosystemseng.2017.09.012>>.
- JONES, Hamlyn G. Application of Thermal Imaging and Infrared Sensing in Plant Physiology and Ecophysiology. p. 107–163, 2004.
- KACIRA, M; LING, P P; SHORT, T H. Establishing Crop Water Stress Index (CWSI) threshold values for early, non-contact detection of plant water stress. *Transactions of the ASAE*, v. 45, n. 3, p. 775–780, 2002.
- KOSCHAN, Andreas; ABIDI, Mongi. *Digital Color Image Processing*. [S.l.]: John Wiley & Sons, 2008.
- KOVAL, L.; VAŇUŠ, J.; BILÍK, P. Distance Measuring by Ultrasonic Sensor. *IFAC-PapersOnLine*, v. 49, n. 25, p. 153–158, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.ifacol.2016.12.026>>.
- KRAMER, Paul J.; O'LEARY, James W. Water Stress and Plant Growth. *Ecology*, v. 51, n. 1, p. 164–165, 1970.
- KUMAR, Anusha *et al.* Internet of things based smart irrigation using regression algorithm. *2017 International Conference on Intelligent Computing, Instrumentation and Control Technologies, ICICICT 2017*, v. 2018- Janua, p. 1652–1657, 2018.
- KUMAR, Navsal *et al.* Crop water stress index for scheduling irrigation of Indian mustard (*Brassica juncea*) based on water use efficiency considerations. *Journal of Agronomy and Crop Science*, v. 206, n. 1, p. 148–159, 2020.
- LUCCHESI, Júlio Rieger *et al.* Estresse salino e hídrico na germinação e crescimento inicial de plântulas de *Toona Ciliata m. roem. var. australis*. *Ciência Florestal, Santa Maria*, v. 28, n. 1, p. 141–149, 2018.
- LUO, Lufeng *et al.* Vision-based extraction of spatial information in grape clusters for harvesting robots. *Biosystems Engineering*, v. 151, p. 90–104, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.biosystemseng.2016.08.026>>.
- MALLICK, Kaniska *et al.* Bridging Thermal Infrared Sensing and Physically-Based Evapotranspiration Modeling: From Theoretical Implementation to Validation Across an Aridity Gradient in Australian Ecosystems. *Water Resources Research*, v. 54, n. 5, p. 3409–3435, 2018.
- MARENGONI, Maurício; STRINGHINI, Stringhini. Tutorial: Introdução à Visão

- Computacional usando OpenCV. *Revista de Informática Teórica e Aplicada*, v. 16, n. 1, p. 125–160, 2010.
- MARTÍNEZ, J. *et al.* A cost-effective canopy temperature measurement system for precision agriculture: a case study on sugar beet. *Precision Agriculture*, v. 18, n. 1, p. 95–110, 2017.
- MARY, Muthiah; PADMA, Lekshmi; JOHN, Maria. Modified Image Segmentation Method based on Region Growing and Region Merging. *Int. Arab J. Inf. Technol*, v. 13, n. 6A, p. 899–907, 2013.
- MASSERONI, Daniele; ARBAT, Gerard; DE LIMA, Isabel Pedroso. Editorial-managing and planning water resources for irrigation: Smart-irrigation systems for providing sustainable agriculture and maintaining ecosystem services. *Water (Switzerland)*, v. 12, n. 1, 2020.
- MESAS-CARRASCOSA, F. J. *et al.* Open source hardware to monitor environmental parameters in precision agriculture. *Biosystems Engineering*, v. 137, p. 73–83, 2015.
- MONTEITH, J. L.; SZEICZ, G. Radiative temperature in the heat balance of natural surfaces. *Quarterly Journal of the Royal Meteorological Society*, v. 88, n. 378, p. 496–507, 1962.
- MONTEITH, John L.; UNSWORTH, Mike H. *Principles of Environmental Physics*. Fourth ed. [S.l.]: Elsevier / Academic Press, 2013.
- MOREIRA, Maurício Alves. *Fundamentos do Sensoriamento Remoto*. [S.l.]: Editora UFV, 2011.
- MOUSAZADEH, Hossein. A technical review on navigation systems of agricultural autonomous off-road vehicles. *Journal of Terramechanics*, v. 50, n. 3, p. 211–232, 2013. Disponível em: <<http://dx.doi.org/10.1016/j.jterra.2013.03.004>>.
- MUANGPRATHUB, Jirapond *et al.* IoT and agriculture data analysis for smart farm. *Computers and Electronics in Agriculture*, v. 156, n. November 2018, p. 467–474, 2019. Disponível em: <<https://doi.org/10.1016/j.compag.2018.12.011>>.
- OTSU, NOBUYUKI. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transaction on Systems, Man and Cybernetics*, v. 20, n. 1, p. 62–66, 1979.
- PALAZZARI, Valeria *et al.* Leaf compatible eco-friendly temperature sensor clip for high density monitoring wireless networks. *Wireless Power Transfer*, v. 4, n. 1, p. 55–60, 2017.
- PEREIRA, Jessica Camila Marmanillo *et al.* Interferência do espaçamento no crescimento da rúcula. *Horticultura Brasileira*, v. 31, n. 2, p. 1418–1425, 2014.
- PÉREZ, A. J. *et al.* Colour and shape analysis techniques for weed detection in cereal fields. *Computers and Electronics in Agriculture*, v. 25, n. 3, p. 197–212, 2000.
- PERISSINI, Ivan Carlos. Análise experimental de algoritmos de constância de cor e segmentação para detecção de mudas de plantas. 2018.

- PRATAMA, Yusrizal *et al.* Implementation Iot (Internet of Things) Smart Farming System on Modern Agriculture. v. 17, n. 4, p. 2723–2731, 2020.
- QU, Xin; DING, Tian-Huai. A Fast Feature Extraction Algorithm for Detection of Foreign Fiber in Lint Cotton within a Complex Background. *Acta Automatica Sinica*, v. 36, n. 6, p. 785–790, 2010. Disponível em: <[http://dx.doi.org/10.1016/S1874-1029\(09\)60036-7](http://dx.doi.org/10.1016/S1874-1029(09)60036-7)>.
- QUEBRAJO, L. *et al.* Linking thermal imaging and soil remote sensing to enhance irrigation management of sugar beet. *Biosystems Engineering*, v. 165, p. 77–87, 2018.
- QUEIRÓS, Leonardo Ribeiro. *Desenvolvimento de um sistema de controle para aplicação a taxa variada e em tempo real de fitorreguladores na cultura do algodoeiro*. 2010. Universidade Estadual de Campinas, 2010.
- RASMUSSEN, Jesper *et al.* Are vegetation indices derived from consumer-grade cameras mounted on UAVs sufficiently reliable for assessing experimental plots? *European Journal of Agronomy*, v. 74, p. 75–92, 2016.
- RATNASINGAM, Sivalogeswaran; MCGINNITY, T. Martin. Chromaticity space for illuminant invariant recognition. *IEEE Transactions on Image Processing*, v. 21, n. 8, p. 3612–3623, 2012.
- RIEHLE, Daniel; REISER, David; GRIEPENTROG, Hans W. Robust index-based semantic plant/background segmentation for RGB- images. *Computers and Electronics in Agriculture*, v. 169, n. July 2019, p. 105201, 2020.
- RUD, Ronit *et al.* Crop water stress index derived from multi-year ground and aerial thermal images as an indicator of potato water status. *Precision Agriculture*, v. 15, n. 3, p. 273–289, 2014.
- RUIZ, Ivan Camilo Arbelaez. *Barra pulverizadora vertical segmentada com controle de distância para a aplicação de agroquímicos*. 2019. Universidade Estadual de Campinas, 2019.
- SANTOS, ANA PAULA DE OLIVEIRA. *Desenvolvimento de Descritores de Imagens para Reconhecimento de Padrões de Plantas Invasoras (Folhas Largas e Folhas Estreitas)*. p. 203, 2009.
- SANTOS, Helane Cristina Aguiar *et al.* Yield of fertigated bell pepper under different soil water tensions and nitrogen fertilization. *Revista Caatinga*, v. 33, n. 1, p. 172–183, 2020.
- SEZEN, S Metin *et al.* Evaluation of crop water stress index (CWSI) for red pepper with drip and furrow irrigation under varying irrigation regimes. *Agricultural Water Management*, v. 143, p. 59–70, 2014.
- SHIRMOHAMMADI, ALIAKBARKHANI Z.; KAMGRA, HAGHIGHI A.A.; SEPASKHAH, ALI REZA. Use of Crop Water Stress Index (CWSI) for evaluation of water

- status and irrigation scheduling of Saffron. *Iranian Journal of Horticultural Science and Technology*, v. 7, n. 1, p. 23–32, 2006.
- SILVA, Cícero J *et al.* Revista Brasileira de Engenharia Agrícola e Ambiental Tomato water stress index as a function of irrigation depths. p. 95–100, 2018.
- SMITH, R.J.; BAILLIE, J.N. Defining precision irrigation: A new approach to irrigation management. *Irrigation and Drainage Conference*, p. 1–6, 2009.
- SRIWASTWA, Apurva *et al.* Detection of Pests Using Color Based Image Segmentation. *Proceedings of the International Conference on Inventive Communication and Computational Technologies, ICICCT 2018*, n. Icicct, p. 1393–1396, 2018.
- SUDIANTO, Agus *et al.* Smart Temperature Measurement System for Milling Process Application Based on MLX90614 Infrared Thermometer Sensor with Arduino. *Journal of Advanced Research in Applied Mechanics*, v. 72, n. 1, p. 10–24, 2020.
- TANDA, G.; CHIARABINI, V. Use of multispectral and thermal imagery in precision viticulture. *Journal of Physics: Conference Series*, v. 1224, n. 1, 2019.
- TANGERINO, Giovana T. Sistemas de sensoriamento embarcado para uso em controle de aplicações de insumos agrícolas à taxa variável. p. 123, 2009.
- TESTI, L. *et al.* Crop water stress index is a sensitive water stress indicator in pistachio trees. *Irrigation Science*, v. 26, n. 5, p. 395–405, 2008.
- THAPA, Sushil *et al.* Canopy temperature depression at grain filling correlates to winter wheat yield in the U.S. Southern High Plains. *Field Crops Research*, v. 217, n. December 2017, p. 11–19, 2018. Disponível em: <<https://doi.org/10.1016/j.fcr.2017.12.005>>.
- TRANI, Paulo espidola; FORNASIER, João Baptista; LISBÃO, Rogério Salles. *Cultura da Rúcula. Boletim Técnico Nº146*. [S.l: s.n.], 1992
- TUCKER, Compton J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, v. 8, n. 2, p. 127–150, 1979.
- VEYSI, Shadman *et al.* A satellite based crop water stress index for irrigation scheduling in sugarcane fields. *Agricultural Water Management*, v. 189, p. 70–86, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2017.04.016>>.
- WALCZAK, Amadeusz; LIPÍŃSKI, Mateusz; JANIK, Grzegorz. Application of the tdr sensor and the parameters of injection irrigation for the estimation of soil evaporation intensity. *Sensors*, v. 21, n. 7, 2021.
- WANG, D.; GARTUNG, J. Infrared canopy temperature of early-ripening peach trees under postharvest deficit irrigation. *Agricultural Water Management*, v. 97, n. 11, p. 1787–1794, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.agwat.2010.06.014>>.

- WANG, Xuezhi *et al.* Automated canopy temperature estimation via infrared thermography : A first step towards automated plant water stress monitoring. *Computers and Electronics in Agriculture*, v. 73, n. 1, p. 74–83, 2010a.
- WANG, Xuezhi *et al.* Automated canopy temperature estimation via infrared thermography: A first step towards automated plant water stress monitoring. *Computers and Electronics in Agriculture*, v. 73, n. 1, p. 74–83, 2010b.
- WOEBBECKE, D. M. *et al.* Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the American Society of Agricultural Engineers*, v. 38, n. 1, p. 259–269, 1995.
- YODER, Ronald E.; ODHIAMBO, Lameck O.; WRIGHT, Wesley C. Effects of Vapor-Pressure Deficit and Net-Irradiance Calculation Methods on Accuracy of Standardized Penman-Monteith Equation in a Humid Climate. *Journal of Irrigation and Drainage Engineering*, v. 131, n. 3, p. 228–237, 2005.
- ZACEPINS, A; STALIDZANS, E; MEITALOVS, J. Application of information technologies in precision apiculture. *Proceedings of the 13th International Conference on Precision Agriculture (ICPA 2012)*, 2012.
- ZHENG, Hengbiao *et al.* Evaluation of RGB, color-infrared and multispectral images acquired from unmanned aerial systems for the estimation of nitrogen accumulation in rice. *Remote Sensing*, v. 10, n. 6, 2018.

7. APÊNDICE 1

O equacionamento dos métodos avaliados para o processamento de imagens no item 3.2.2 é mostrado neste apêndice, onde o ID1 representa o modelo HSV, que propõe a dissociação do Valor, elemento acromático de uma imagem, dos elementos que carregam as informações de cor (Matiz e Saturação), proporcionando uma melhor percepção das cores. A conversão de uma imagem em RGB para o modelo HSV pode ser feita pixel a pixel, utilizando as equações 12,13 e 14, considerando que os valores estão normalizados num intervalo entre 0 e 1:

- *Value* (Valor): Mensura a intensidade da luz, que indica a noção acromática de brilho. Sua representatividade é a mesma das imagens em escala cinza.

$$V \leftarrow \max(R, G, B) \quad [\text{Equação 12}]$$

- *Hue* (Matiz): Indica qual tipo de cromaticidade que a cor possui, descrevendo cores puras, como azul, vermelho ou verde.

$$H \leftarrow \begin{cases} 60(G - B)/(V - \min(R, G, B)) & \text{se } V = R \\ 120 + 60(B - R)/(V - \min(R, G, B)) & \text{se } V = G \\ 240 + 60(R - G)/(V - \min(R, G, B)) & \text{se } V = B \end{cases} \quad [\text{Equação 13}]$$

- *Saturation* (Saturação): Indica o grau de pureza de determinada cor, ou seja, quão diluída a cor pura se encontra na luz branca.

$$S \leftarrow \begin{cases} \frac{V - \min(R, G, B)}{V} & , \text{se } V \neq 0 \\ 0 & , \text{se } V = 0 \end{cases} \quad [\text{Equação 14}]$$

O ID2 também apresenta a mesma abordagem de ID1(HSV), porém sua limiarização foi realizada pelo método Otsu¹, enquanto a da primeira foi obtida a partir do histograma calculado para a imagem HSV, isto é, a imagem gerada após a conversão.

O modelo CrCbCg (Cg), representado pelo ID3, é derivado do modelo YCrCb (ID5), o qual é largamente utilizado como modelo de caracterização de cores de imagens (QU; DING, 2010) por considerar os efeitos de luminosidade (Y) e cromaticidade (Cr e Cb), onde o Cr é proveniente da banda R, o Cb da banda B e, para formar um cubo de cores relacionando as três, têm-se o Cg o qual é derivado da banda G. As equações para conversão de uma imagem RGB em CrCbCg são:

¹ O método de Otsu requer apenas os valores do histograma da imagem, isto é, uma representação da quantidade de pixels em cada nível de intensidade para determinar o seu limiar ótimo (OTSU, 1979)

$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 16 \\ 128 \\ 128 \end{bmatrix} + \begin{bmatrix} 0,299 & 0,587 & 0,114 \\ -0,169 & -0,331 & 0,50 \\ 0,50 & -0,419 & -0,081 \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad [\text{Equação 15}]$$

$$Cg = 0.50 - 0,362R + 0,50G - 0,138B \quad [\text{Equação 16}]$$

A diferença existente entre o modelo ID3 e o modelo ID4 se dá pelo fato de que no CrCgCb(Cg) utiliza-se a abordagem da cromaticidade derivada da banda G (Cg) aplicada na imagem CrCgCb e no outro, aplica-se o índice *Exces Green* nesta mesma imagem. Vale lembrar que, para ambos as abordagens (ID 3 e ID 4) o limiar foi determinado por meio do histograma gerado para cada *output*.

O ID5 apresenta um modelo já mencionado, porém aplicados com a abordagem das cromaticidades provenientes das bandas de cor verde e azul. A imagem, resultado da aplicação desse modelo (YCrCgCb) na imagem RGB normalizada, foi binarizada segundo o valor *target* gerado por meio do seu histograma.

O índice de vegetação *Excess Green* (ID6), avaliado por WOEBBECKE *et al.*, (1995) apresentou bons resultados na remoção do plano de fundo (solo) das imagens. Representado pela Equação 17, se tornou amplamente citado em outros estudos (GUERRERO *et al.*, 2012; JIANG; WANG; LIU, 2015; LUO *et al.*, 2016; RIEHLE; REISER; GRIEPENTROG, 2020). A limiarização nesse caso, seguiu a mesma dos modelos ID3 e ID4.

$$ExG = (2G) - R - B \quad [\text{Equação 17}]$$

As abordagens apresentadas pelos IDs 7 e 8 utilizam os valores do sistema XYZ, fazendo-se necessária a conversão do RGB (Equação 18). Como seus canais estão relacionados à percepção visível de tom e saturação de cores, ambas são conhecidas como espaços de cor uniformes (KOSCHAN; ABIDI, 2008). Nos dois modelos existe a separação da representação das cores com a luminosidade (L), onde no espaço $L^*a^*b^*$, o canal a^* refere-se ao eixo verde-vermelho, e o canal b^* ao eixo azul-amarelo. Já no modelo $L^*u^*v^*$ os canais u^* e v^* são definidos como transformações não-lineares de X e Y respectivamente, que constituem a base dos modelos tri-cromáticos e de diversos outros espaços de cor (GARCÍA-MATEOS *et al.*, 2015; KOSCHAN; ABIDI, 2008). A limiarização para ambos os modelos seguiu o método de *Otsu* (OTSU, 1979). As equações para essa conversão foram:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,412453 & 0,357580 & 0,180423 \\ 0,212671 & 0,715160 & 0,072169 \\ 0,019334 & 0,119193 & 0,0950227 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad [\text{Equação 18}]$$

$$L \leftarrow \begin{cases} 116 \times \sqrt[3]{Y}, & Y > 0,008856 \\ 903,3 \times Y, & Y \leq 0,008856 \end{cases} \quad [\text{Equação 19}]$$

$$\begin{aligned} a &\leftarrow 500(f(X) - f(Y)) \\ b &\leftarrow 200(f(Y) - f(Z)) \end{aligned} \quad [\text{Equação 20}]$$

$$f(t) = \begin{cases} t^{\frac{1}{3}}, & t > 0,008856 \\ 7,787t + 16/116, & t \leq 0,008856 \end{cases} \quad [\text{Equação 21}]$$

$$\begin{aligned} u' &\leftarrow 4 * X / (X + 15Y + 3Z) \\ v' &\leftarrow 9 * Y / (X + 15Y + 3Z) \end{aligned} \quad [\text{Equação 22}]$$

$$\begin{aligned} u &\leftarrow 13 * L * (u' - u_n) \text{ onde } u_n = 0,19793943 \\ v &\leftarrow 13 * L * (v' - v_n) \text{ onde } v_n = 0,46831096 \end{aligned} \quad [\text{Equação 23}]$$

O índice de vegetação NDI (*Normalized Vegetation Index*), indicado pelo ID9, proposto por PÉREZ *et al.*, (2000), leva em consideração as bandas de cores vermelho e verde. O limiar para esta abordagem foi definido a partir do histograma da imagem NDI. Esse modelo pode ser calculado a partir da Equação 24.

$$NDI = \frac{G-R}{G+R} \quad [\text{Equação 24}]$$

O último método mostrado na Tabela 1 (ID10) denominado L1L2L3 (L3), foi proposto e desenvolvido com intuito de criar um modelo independente das variações de luminosidade em objetos foscos ou brilhantes (GEVERS; SMEULDERS, 1997). Possui um alto poder de segmentação sob luz branca, reduzindo os efeitos de destaques luminosos, orientação da superfície e também variações de intensidade da luz incidente, mas é sensível às variações de cor nessa luz (PERISSINI, 2018). Para este trabalho a sua limiarização foi realizada baseada nos dados do histograma da imagem $l_1l_2l_3$. Suas formulações são apresentadas nas Equações 25, 26 e 27.

$$l1 = \frac{(R-G)^2}{(R-G)^2 + (R-B)^2 + (G-B)^2} \quad [\text{Equação 25}]$$

$$l2 = \frac{(R-B)^2}{(R-G)^2 + (R-B)^2 + (G-B)^2} \quad [\text{Equação 26}]$$

$$l3 = \frac{(G-B)^2}{(R-G)^2 + (R-B)^2 + (G-B)^2} \quad [\text{Equação 27}]$$

8. APÊNDICE 2

Tabela 6 – Dados estatísticos obtidos pela métrica F-score calculada para os 10 modelos avaliados, onde nota-se o ExG(RGB) como o modelo com a segunda maior média e com a menor amplitude entre as amostras.

	F-Score									
	<i>HSV</i> <i>Intervalado</i>	<i>HSV(t)</i>	<i>CrCb(Cg)</i>	<i>CrCb(ExG)</i>	<i>YCrCb(Cr+Cb)</i>	<i>ExG (RGB)</i>	<i>L*u*v*(u*-v*)</i>	<i>L*a*b*(b*-a*)</i>	<i>NDI</i>	<i>L1L2L3(L3)</i>
Média	81,31%	81,32%	86,22%	86,95%	83,06%	86,54%	85,27%	85,11%	74,16%	79,12%
Erro-padrão	0,97%	0,94%	0,95%	0,68%	1,88%	0,66%	0,74%	0,79%	4,61%	1,10%
Mediana	80,94%	80,95%	86,62%	86,93%	84,70%	87,14%	85,06%	85,10%	81,51%	79,57%
Desvio-padrão	3,76%	3,76%	3,79%	2,70%	7,54%	2,65%	2,98%	3,16%	18,42%	4,39%
Variância da amostra	0,14%	0,14%	0,14%	0,07%	0,57%	0,07%	0,09%	0,10%	3,39%	0,19%
Curtose	3,75	3,76	1,09	2,47	12,85	1,56	0,01	-0,03	6,38	-0,15
Assimetria	0,87	0,86	-0,96	-0,87	-3,46	-0,81	-0,26	-0,39	-2,37	-0,50
Intervalo	18,05%	18,05%	13,89%	11,84%	31,87%	10,80%	11,05%	11,20%	75,33%	16,05%
Mínimo	73,46%	73,46%	76,67%	79,82%	56,03%	80,72%	78,92%	78,29%	16,25%	70,29%
Máximo	91,51%	91,52%	90,56%	91,65%	87,90%	91,52%	89,97%	89,48%	91,58%	86,34%
Contagem	15	15	15	15	15	15	15	15	15	15
Nível de confiança (95,0%)	2,00%	2,00%	2,02%	1,44%	4,02%	1,41%	1,59%	1,68%	9,82%	2,34%

Tabela 7 - Dados estatísticos obtidos pela métrica Acurácia calculada para os 10 modelos avaliados, onde nota-se o ExG(RGB) como o modelo que apresentou a maior média e com o menor erro padrão entre as amostras.

	Acurácia									
	<i>HSV</i> <i>Intervalado</i>	<i>HSV(t)</i>	<i>CrCb(Cg)</i>	<i>CrCb(ExG)</i>	<i>YCrCb(Cr+Cb)</i>	<i>ExG (RGB)</i>	<i>L*u*v*(u*-v*)</i>	<i>L*a*b*(b*-a*)</i>	<i>NDI</i>	<i>L1L2L3(L3)</i>
Média	82,51%	82,52%	88,44%	89,89%	88,52%	90,04%	87,64%	87,54%	81,07%	79,77%
Erro-padrão	1,44%	1,43%	1,11%	0,73%	0,58%	0,57%	0,82%	0,89%	2,39%	1,98%
Mediana	81,99%	81,99%	89,24%	90,33%	89,50%	90,01%	87,97%	88,13%	81,87%	79,94%
Desvio-padrão	5,76%	5,76%	4,43%	2,92%	2,28%	2,31%	3,28%	3,56%	9,56%	7,94%
Variância da amostra	0,33%	0,33%	0,20%	0,09%	0,05%	0,05%	0,11%	0,13%	0,91%	0,63%
Curtose	1,82	1,81	0,68	1,84	-0,91	1,97	1,82	1,35	6,55	0,35
Assimetria	1,15	1,14	-0,29	-0,32	-0,62	0,09	0,58	0,47	-1,87	-0,07
Intervalo	22,19%	22,19%	18,44%	13,14%	7,43%	10,47%	14,12%	14,97%	46,30%	31,64%
Mínimo	75,49%	75,49%	79,09%	83,09%	84,49%	84,99%	81,81%	81,27%	51,40%	64,40%
Máximo	97,68%	97,68%	97,52%	96,23%	91,92%	95,46%	95,93%	96,23%	97,70%	96,04%
Contagem	15	15	15	15	15	15	15	15	15	15
Nível de confiança (95,0%)	3,07%	3,07%	2,36%	1,56%	1,21%	1,23%	1,75%	1,89%	5,09%	4,23%

Tabela 8 - Dados estatísticos obtidos pelo tempo de processamento, onde nota-se que o ExG(RGB) resultou no segundo menor valor, revelando-se um modelo menos complexo e que não necessita de alta capacidade computacional.

	Tempo de Processamento									
	<i>HSV</i> <i>Intervalado</i>	<i>HSV(t)</i>	<i>CrCb(Cg)</i>	<i>CrCb(ExG)</i>	<i>YCrCb(Cr+Cb)</i>	<i>ExG (RGB)</i>	<i>L*u*v*(u*-v*)</i>	<i>L*a*b*(b*-a*)</i>	<i>NDI</i>	<i>L1L2L3(L3)</i>
Média	6,97	6,95	5,10	5,10	5,16	1,50	17,29	9,42	0,86	1,93
Erro-padrão	0,10	0,11	0,08	0,08	0,08	0,01	0,21	0,13	0,04	0,08
Mediana	6,88	6,83	5,13	5,13	5,19	0,50	17,35	9,35	0,83	1,85
Desvio-padrão	0,41	0,43	0,31	0,31	0,30	0,03	0,85	0,53	0,14	0,32
Variância da amostra	0,17	0,19	0,09	0,10	0,09	0,00	0,72	0,28	0,02	0,10
Curtose	0,89	-0,35	-1,21	-1,35	-1,21	-0,81	-1,08	-0,18	8,82	11,93
Assimetria	0,74	0,56	-0,06	-0,14	-0,10	-0,50	-0,10	0,54	2,67	3,28
Intervalo	1,60	1,51	0,91	0,94	0,94	0,10	2,71	1,85	0,62	1,33
Mínimo	6,36	6,32	4,66	4,61	4,72	0,44	15,99	8,69	0,72	1,72
Máximo	7,96	7,83	5,58	5,56	5,66	0,54	18,71	10,54	1,34	3,05
Contagem	15	15	15	15	15	15	15	15	15	15
Nível de confiança (95,0%)	0,22	0,23	0,16	0,16	0,16	0,02	0,45	0,28	0,08	0,17




Figura 26 – Análise de Regressão e Residual para a NWSB parametrizada em ambiente protegido.




Figura 27 - Análise de Regressão e Residual para a NWSB parametrizada em ambiente desprotegido.

Tabela 9 – Médias Móveis Exponencialmente Potenciais dos Tratamentos 1,2 e 3, calculadas para as variáveis de CWSI e CVA, onde pode-se observar que nenhum ponto de Z saiu fora dos limites LSC e LIC, confirmando a estabilidade do processo.

Tratamento 1										
Dias após plantio	CWSI 1	Z1	LSC1	LIC1	Média1	CVA 1	Z1	LSC1	LIC1	Média1
10	0,0457	0,0535	0,0650	0,0437	0,0544	94,10	90,30	90,85	88,91	89,88
17	0,1025	0,0584	0,0686	0,0402	0,0544	85,81	89,85	91,17	88,59	89,88
25	0,0072	0,0533	0,0714	0,0374	0,0544	91,21	89,99	91,42	88,34	89,88
32	0,0621	0,0542	0,0729	0,0358	0,0544	88,40	89,83	91,56	88,20	89,88
Média	0,0544					89,88				
Desvpad	0,0395					3,57				

Tratamento 2										
Dias após plantio	CWSI 2	Z2	LSC2	LIC2	Média2	CVA 2	Z2	LSC2	LIC2	Média2
10	0,1739	0,2284	0,2460	0,2230	0,2345	84,33	81,29	81,57	80,35	80,96
17	0,2513	0,2307	0,2499	0,2191	0,2345	80,00	81,17	81,77	80,14	80,96
25	0,2731	0,2350	0,2529	0,2161	0,2345	79,50	81,00	81,93	79,99	80,96
32	0,2397	0,2354	0,2546	0,2144	0,2345	80,00	80,90	82,02	79,89	80,96
Média	0,2345					80,96				
Desvpad	0,0427					2,26				

Tratamento 3										
Dias após plantio	CWSI 3	Z3	LSC3	LIC3	Média3	CVA 3	Z3	LSC3	LIC3	Média3
10	0,2679	0,2378	0,3304	0,2089	0,2345	70,60	65,50	66,24	63,62	64,93
17	0,3230	0,2464	0,3349	0,1729	0,2345	64,72	65,42	66,67	63,19	64,93
25	0,3840	0,2601	0,3384	0,1449	0,2345	58,80	64,76	67,01	62,85	64,93
32	0,2927	0,2634	0,3404	0,1289	0,2345	65,60	64,84	67,20	62,66	64,93
Média	0,3169					64,93				
Desvpad	0,0501					4,84				