UNIVERSIDADE FEDERAL DO CEARÁ

CENTRO DE CIÊNCIAS AGRÁRIAS

DEPARTAMENTO DE CIÊNCIA DO SOLO

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DO SOLO

THIAGO COSTA DOS SANTOS

AVALIAÇÃO DE MODELOS PARAMÉTRICOS E NÃO PARAMÉTRICOS EM ESTIMATIVA DE ÍNDICE DE SUSCETIBILIDADE À DESERTIFICAÇÃO

FORTALEZA

2023

THIAGO COSTA DOS SANTOS

AVALIAÇÃO DE MODELOS PARAMÉTRICOS E NÃO PARAMÉTRICOS EM ESTIMATIVA DE ÍNDICE DE SUSCETIBILIDADE A DESERTIFICAÇÃO

Tese apresentada ao Programa de Pós-Graduação em Ciência do Solo da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Doutor em Ciência do solo. Área de concentração: Pedologia.

Orientador: Prof. Dr. Raul Shiso Toma.

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

S239a Santos, Thiago Costa dos.
Avaliação de modelos paramétricos e não paramétricos em estimativa de índice de suscetibilidade a desertificação / Thiago Costa dos Santos. – 2023.
138 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Programa de Pós-Graduação em Ciência do Solo, Fortaleza, 2023.
Orientação: Prof. Dr. Raul Shiso Toma.

1. Zoneamento Ecológico Econômico . 2. Sensoriamento Remoto. 3. Solo Exposto. I. Título.
CDD 631.4

THIAGO COSTA DOS SANTOS

AVALIAÇÃO DE MODELOS PARAMÉTRICOS E NÃO PARAMÉTRICOS EM ESTIMATIVA DE ÍNDICE DE SUCEPTIBILIDADE À DESERTIFICAÇÃO

Tese apresentada ao Programa de Pós-Graduação em Ciência do Solo da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Doutorado em Ciência do solo. Área de concentração: Pedologia.

Aprovada em: 23/01/2023.

BANCA EXAMINADORA

_____

Prof. Dr. Raul Shiso Toma (Orientador)
Universidade Federal do Ceará (UFC)

_____

Prof. Dra. Isabel Cristina da Silva Araújo
Universidade Federal do Ceará (UFC)

_____

Prof. Dr. Jaedson Cláudio Anunciato Mota
Universidade Federal do Ceará (UFC)

_____

Prof. Dr. Luis Clenio Jário Moreira
Instituto Federal do Ceará (IFCE)

_____

Prof. Dr. Ricardo Espíndola Romero
Universidade Federal do Ceará (UFC)

A Deus, Aos meus pais, A minha querida irmã Tamires Taiane Costa dos Santos (*In memoriam*), a minha querida avô paterna Zulmira Moreira de Oliveira (*In memoriam)* e minha esposa Jozeany Amorim pelo carinho e apoio nesta jornada.

AGRADECIMENTOS

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

A Deus, pela saúde, fé, força e coragem para enfrentar os desafios da vida.

Aos meus pais por me ensinarem sempre a ser honesto, humilde, batalhador e respeitar ao próximo.

A minha Avó paterna (*in memorian*) pelo carinho e apoio em toda minha vida.

A minha Querida Irmã Tamires Taiane (*in memorian*) por sempre acreditar em meio potencial e desejar a mim tudo que um homem de bom possa ter na vida.

Ao Prof. Dr. Raul Shiso Toma, pela excelente orientação, paciência e amizade.

Ao Prof. Dr. Luis Clênio Jário Moreira, pelos ensinamentos e dicas para realização do trabalho.

Ao Prof. Phd Adunias dos Santos Teixeira, pelo aprendizado na disciplina de Programação.

Ao Programa de Pós-graduação em Ciência do Solo da UFC, pela nobre oportunidade.

À CAPES, pelo apoio financeiro com a manutenção da bolsa de auxílio.

Ao PROAP e Pro – Integração pelas ajudas de custo para com a realização desta pesquisa.

Aos funcionários do departamento de Ciência do solo, pelo apoio e auxílio de atividades em laboratório.

Aos colegas de pós-graduação, pela boa convivência e amizade nestes 60 meses de intenso aprendizado.

RESUMO

A desertificação é o processo de degradação dos recursos naturais em razão do aumento da pressão antrópica que acarreta em alterações nas dinâmicas dos ecossistemas e nas variáveis climáticas. Parte significativa das metodologias de monitoramento da desertificação baseiam-se em modelos que empregam índices com ponderações subjetivas que aumentam as incertezas dos modelos sem identificar as causas, dificultando a adoção de estratégias de controle eficiente. Este trabalho está alicerçado nas seguintes hipóteses: 1) Os modelos paramétricos (Regressão múltipla e Logística) e não paramétricos (Redes Neurais e SVM) são capazes de predizerem a suscetibilidade a desertificação, quantificando os efeitos das mudanças nas condições da vegetação, solo e clima entendidos como causadores da desertificação; 2) partindo da premissa de que os modelos de predição de suscetibilidade a desertificação estão restritos a abordagens locais sem considerar os regimes de precipitações é possível haver diferenças destes quando empregados em nível regional e local e sob condições de seca ou chuva. Foram usadas imagens dos sensores TM, ETM+ e OLI entre 1997 a 2018 em finais de períodos secos e chuvosos para quantificação do NDVI, TGSI, albedo, temperatura, evapotranspiração, índice de aridez e precipitação e para construção do índice geométrico de suscetibilidade a desertificação (IGSD). O IGSD foi calculado pelas ponderações dos índices e constituiu o Y dos modelos, as variáveis explicativas (X) foram os próprios índices. Os resultados dos modelos foram avaliados mediante acurácia, kappa, médias de erros de omissão (MEO), de comissão (MEC) e de taxa de acerto de campo (MTAC) em escala local e regional. Os resultados mostraram que os modelos de RLM e RL produziram mapas com melhores métricas e maiores MTAC em nível local e regional, por outro lado a rede neural e o SVM são promissores a nível local. O NDVI, Albedo, Evapotranspiração, Temperatura e Índice de Aridez mostraram-se mais importantes na suscetibilidade a desertificação a nível local e regional, sendo que o aumento do NDVI e Índice de Aridez reduziram a média do IGSD e o riscos a desertificação, enquanto o aumento do albedo, temperatura e evapotranspiração resultaram em aumentos nas médias do IGSD e nos riscos a desertificação. O desmatamento desordenado, aumento de áreas ocupadas por pastagens e de pastagens degradadas justificam à redução da cobertura vegetal e aumento do albedo, temperatura e evapotranspiração, impactando a precipitação e o índice de aridez, aumentando os riscos a desertificação. Portanto os modelos paramétricos e não paramétricos têm potencial na identificação da suscetibilidade a desertificação e suas causas, além de mostrar em termos quantitativos a contribuição de cada índice no aumento ou redução do risco à desertificação.

Palavras-chave: zoneamento ecológico econômico; sensoriamento remoto; solo exposto.

ABSTRACT

Desertification is process of degradation of natural resources due to the increase in anthropic pressure that leads to changes in the dynamics of ecosystems and climate variables. A significant part of the methodologies for monitoring desertification are based on models what considering index with subjective weights that increase the uncertainties of the models without identifying the causes, making it difficult to adopt efficient control strategies. This work is based on the following hypotheses: 1) parametric models (multiple regression and logistic) and non-parametric models (neural networks and SVM) are capable of predicting susceptibility to desertification, quantifying the effects of changes in vegetation, soil and climate conditions understood as causing desertification; 2) starting from the premise that the prediction models of susceptibility to desertification are restricted to local approaches without considering the precipitation regimes, it is possible that there are differences in these when used at regional and local levels and under conditions of drought or rain. Images from the TM, ETM+ and OLI sensors were used between 1997 and 2018 at the end of dry and rainy periods to quantify the NDVI, TGSI, albedo, temperature, evapotranspiration, aridity and precipitation index and to construct the geometric index of susceptibility to desertification (IGSD). The IGSD was calculated by weight the indices and constituted the Y of the models, the explanatory variables (X) were the indices themselves. The results of the models were evaluated using accuracy, kappa, average errors of omission (MEO), commission (MEC) and field hit rate (MTAC) on a local and regional scale. The results showed that the RLM and RL models produced maps with better metrics and higher MTAC at the local and regional level, on the other hand the neural network and the SVM are promising at the local level. The NDVI, albedo, evapotranspiration, temperature and aridity index were more important in the susceptibility to desertification at the local and regional level, and the increase in the NDVI and aridity index reduced the IGSD average and the risk of desertification, while the increases in albedo, temperature and evapotranspiration resulted in increased in IGSD averages and in risks to desertification. Disorderly deforestation, increase in areas occupied by pastures and degraded caused the reduction of vegetation cover and increase in albedo, temperature and evapotranspiration, impacting precipitation and the aridity index, increasing the risks of desertification. Therefore, parametric and non-parametric models have the potential to identify susceptibility to desertification and its causes, in addition to showing in quantitative terms the contribution of each index in increasing or reducing the risk of desertification.

Keywords: economic ecological zoning; remote sensing; bare soil.

LISTA DE ILUSTRAÇÕES

Figura 1 – Localização de Irauçuba Centro Norte (regional)..... 30

Figura 2 – Localização Espacial Miraíma 33

Figura 3 – Localização Espacial de Canindé..... 33

Figura 4 – Localização Espacial Irauçuba..... 35

Figura 5 – Localização Espacial Santa Quitéria..... 35

Figura 6 – Metodologia do Trabalho de Tese..... 58

Figura 7 – Mapa de IGSD em Miraíma (RLM – 2005FC)..... 63

Figura 8 – Mapa de IGSD em Miraíma (RL – 2000FS)..... 63

Figura 9 – Mapa de IGSD em Miraíma (redes neurais – 2005FC)..... 64

Figura 10 – Mapa de IGSD em Miraíma (SVM – 2003FS)..... 64

Figura 11 – Mapa de IGSD em Canindé (RLM – 1997FC) 72

Figura 12 – Mapa de IGSD em Canindé (RL – 1997FC) 72

Figura 13 – Mapa de IGSD em Canindé (redes neurais – 2006FC)..... 73

Figura 14 – Mapa de IGSD em Canindé (SVM – 1998FC)..... 73

Figura 15 – Mapa de IGSD em Irauçuba (RLM - 1997FC)..... 80

Figura 16 – Mapa de IGSD em Irauçuba (RL – 2005FC)..... 80

Figura 17 – Mapa de IGSD em Irauçuba (redes neurais – 1999FC)..... 81

Figura 18 – Mapa de IGSD em Irauçuba (SVM – 2012FS)..... 81

Figura 19 – Mapa de IGSD Santa Quitéria (RLM - 2018FC)..... 88

Figura 20 – Mapa de IGSD Santa Quitéria (RL – 2018FC)..... 88

Figura 21 – Mapa de IGSD Santa Quitéria (redes neurais – 2011FS)..... 89

Figura 22 – Mapa de IGSD Santa Quitéria (SVM – 2016FC)..... 89

Figura 23 – Mapa de IGSD em ICN (RLM - 1999FC)..... 96

Figura 24 – Mapa de IGSD em ICN (RL - 2001FC)..... 96

Figura 25 – Mapa de IGSD em ICN (Redes Neurais - 2000FS)..... 97

Figura 26 – Mapa de IGSD em ICN (SVM - 2001FC)..... 97

LISTA DE TABELAS

Tabela 1 – Períodos de imagens adquiridos da série Landsat 05, 07 e 08..... 36

Tabela 2 – Descrição de bandas do sensor TM..... 38

Tabela 3 – Descrição de bandas do OLI..... 39

Tabela 4 – Coeficientes usados no cálculo do albedo..... 40

Tabela 5 – Ponderações dos índices usados no IGSD..... 49

Tabela 6 – Valores de ESAI usados como referência para classificação do IGSD..... 50

Tabela 7 – Classificação da suscetibilidade a desertificação..... 52

Tabela 8 – Índices e contribuições no IGSD e no risco a desertificação em Miraíma.... 60

Tabela 9 – Métricas dos modelos nas fases de validação e teste em Miraíma..... 60

Tabela 10 – RLM, Redes Neurais e SVM nas etapas de validação e teste em Miraíma... 61

Tabela 11 – Métricas dos modelos testados em Miraíma..... 62

Tabela 12 – Correlações de índices em Miraíma..... 66

Tabela 13 – Índices e contribuições no IGSD e no risco a desertificação em Canindé..... 69

Tabela 14 – Métricas dos modelos nas fases de validação e teste em Canindé..... 69

Tabela 15 – RLM, Redes Neurais e SVM nas etapas de validação e teste em Canindé.... 70

Tabela 16 – Métricas dos modelos testados em Canindé..... 70

Tabela 17 – Correlações de índices em Canindé..... 75

Tabela 18 – Índices e contribuições no IGSD e no risco a desertificação em Irauçuba.... 77

Tabela 19 – Métricas dos modelos nas fases de validação e teste em Irauçuba..... 78

Tabela 20 – RLM, Redes Neurais e SVM nas etapas de validação e teste em Irauçuba... 78

Tabela 21 – Métricas dos modelos testados em Irauçuba..... 79

Tabela 22 – Correlações de índices em Irauçuba..... 83

Tabela 23 – Índices e contribuições no risco a desertificação em Santa Quitéria..... 85

Tabela 24 – Métricas dos modelos nas fases de validação e teste em Santa Quitéria..... 86

Tabela 25 – RLM, Redes Neurais e SVM em validação e teste em Santa Quitéria..... 86

Tabela 26 – Métricas dos modelos testados em Santa Quitéria..... 87

Tabela 27 – Correlações entre os índices em Santa Quitéria..... 91

Tabela 28 – Índices e contribuições no IGSD e no risco a desertificação em ICN..... 93

Tabela 29 – Métricas nas fases de validação e teste em Irauçuba Centro Norte..... 94

Tabela 30 – RLM, Redes Neurais e SVM nas etapas de validação e teste em ICN..... 94

Tabela 31 – Métricas dos modelos testados em ICN..... 95

Tabela 32 – Correlações entre os índices de ICN..... 99

SUMÁRIO

1	**INTRODUÇÃO**	17
2	**OBJETIVO GERAL**	18
2.1	**Objetivos Específicos**	18
3	**REVISÃO DE LITERATURA**	19
3.1	**Desertificação no mundo**	19
3.2	**Desertificação no Brasil**	20
3.3	**Desertificação no Nordeste**	21
3.4	**Modelos de monitoramento da desertificação**	22
3.5	**Sensoriamento remoto no estudo de desertificação**	24
3.6	**Modelos paramétricos**	25
3.6.1	***Regressão Múltipla***	25
3.6.2	***Regressão Logística***	25
3.7	**Modelos Não Paramétricos**	26
3.7.1	***Redes Neurais Artificiais***	27
3.7.2	***Support Vector Machine (SVM)***	28
4	**METODOLOGIA**	29
4.1	**Áreas de estudo**	29
4.1.1	***Irauçuba Centro Norte (Dimensão Regional)***	29
4.1.2	***Unidades Territoriais (Dimensão Local)***	31
4.2	**Aquisição e processamento de imagens**	36
4.3	**Cálculo dos índices**	37
4.3.1	***NDVI, TGSI, Albedo***	37
4.3.2	***Temperatura***	40
4.3.3	***Precipitação***	41
4.3.4	***Índice de Aridez***	42
4.3.5	***Evapotranspiração Horária (ETh)***	43
4.3.5.1	*Saldo de Radiação (Rn)*	44
4.3.5.2	*Fluxo de Calor no Solo (G)*	44
4.3.5.3	*Fluxo de Calor Sensível (H)*	44
4.3.5.4	*Fluxo de Calor Latente (LE)*	48
4.3.5.5	*Evapotranspiração Horária (ETh)*	48

4.4 **Construção do Índice Geométrico de Suscetibilidade a Desertificação**..... 48
4.5 **Modelos Paramétricos**..... 50
4.5.1 ***Regressão Múltipla***..... 50
4.5.2 ***Regressão Logística***..... 51
4.6 **Modelos Não Paramétricos**..... 52
4.7 **Avaliações e métricas de desempenhos dos modelos**..... 53
4.8 **Construção e validação do Mapa de IGSD**..... 56
4.9 **Validação em Campo**..... 57
4.10 **Metodologia do trabalho de tese**..... 57
5 **RESULTADOS E DISCUSSÕES**..... 59
5.1 **Miraíma**..... 59
5.1.1 ***RLM, RL, Redes Neurais e SVM***..... 59
5.1.2 ***Mapas de IGSD em Miraíma (RLM, RL, Redes Neurais e SVM)***..... 62
5.2 **Canindé**..... 68
5.2.1 ***RLM, RL, Redes Neurais e SVM***..... 68
5.2.2 ***Mapas de IGSD para Canindé (RLM, RL, Redes Neurais e SVM)***..... 71
5.3 **Irauçuba**..... 76
5.3.1 ***RLM, RL, Redes Neurais e SVM***..... 76
5.3.2 ***Mapas de IGSD para Irauçuba (RLM, RL, Redes Neurais e SVM)***..... 79
5.4 **Santa Quitéria**..... 85
5.4.1 ***RLM, RL, Redes Neurais e SVM em Santa Quitéria***..... 85
5.4.2 ***Mapas de IGSD para Santa Quitéria (RLM, RL, Redes Neurais e SVM***..... 87
5.5 **Irauçuba Centro Norte (Regional)** 93
5.5.1 ***RLM, RL, redes neurais e SVM***..... 93
5.5.2 ***Mapas de IGSD em ICN (RLM, RL, Redes Neurais e SVM)***..... 95
6 **CONCLUSÕES** 100
REFERÊNCIAS 102
APÊNDICE A – ESTATÍSTICA DESCRITIVA MIRAÍMA 110
APÊNDICE B – MODELOS DE REGRESSÃO MÚLTIPLA EM MIRAÍMA..... 111
APÊNDICE C – MODELOS DE REGRESSÃO LOGÍSTICA EM MIRAÍMA..... 112

APÊNDICE D – MODELOS DE REDES NEURAIS E SVM EM MIRAÍMA..... 113
APÊNDICE E – MATRIZ DE CONFUSÃO MODELOS DE MIRAÍMA..... 114
APÊNDICE F – ESTATÍSTICA DESCRITIVA CANINDÉ..... 115
APÊNDICE G – MODELOS DE REGRESSÃO MÚLTIPLA EM CANINDÉ..... 116
APÊNDICE H – MODELOS DE REGRESSÃO LOGÍSTICA EM CANINDÉ..... 117
APÊNDICE I – MODELOS DE REDES NEURAIS E SVM EM CANINDÉ..... 119
APÊNDICE J – MATRIZ DE CONFUSÃO MODELOS DE CANINDÉ..... 120
APÊNDICE L – ESTATÍSTICA DESCRITIVA IRAUÇUBA..... 121
APÊNDICE M – MODELOS DE REGRESSÃO MÚLTIPLA EM IRAUÇUBA..... 122
APÊNDICE N – MODELOS DE REGRESSÃO LOGÍSTICA EM IRAUÇUBA..... 123
APÊNDICE O – MODELOS DE REDES NEURAIS E SVM EM IRAUÇUBA..... 125
APÊNDICE P – MATRIZ DE CONFUSÃO MODELOS DE IRAUÇUBA..... 126
APÊNDICE Q – ESTATÍSTICA DESCRITIVA SANTA QUITÉRIA..... 127
APÊNDICE R – MODELOS DE REGRESSÃO MÚLTIPLA EM SANTA QUITÉRIA..... 128
APÊNDICE S – MODELOS DE REGRESSÃO LOGÍSTICA EM SANTA QUITÉRIA..... 130
APÊNDICE T – MODELOS DE REDES NEURAIS E SVM EM SANTA QUITÉRIA..... 131

APÊNDICE U – MATRIZ DE CONFUSÃO MODELOS DE SANTA QUITÉRIA..... 132
APÊNDICE V – ESTATÍSTICA DESCRITIVA ICN..... 133
APÊNDICE X – MODELOS DE REGRESSÃO MÚLTIPLA EM ICN..... 134
APÊNDICE Z – MODELOS DE REGRESSÃO LOGÍSTICA EM ICN..... 135
APÊNDICE AA – MODELOS DE REDES NEURAIS E SVM EM ICN..... 137
APÊNDICE AB – MATRIZ DE CONFUSÃO MODELOS ICN..... 138

1 INTRODUÇÃO

A desertificação é o processo de degradação que ocorre em regiões de clima árido, semiárido e sub úmido seco decorrente da pressão exercida pelas atividades antrópicas que alteram as condições de equilíbrio dos solos, vegetação e biodiversidades acarretando alterações climáticas que levam ao aumento de escassez hídrica resultando em menor cobertura vegetal, erosão, perda de nutrientes, compactação do solo e consequentemente perda do potencial agrícolas das terras.

Cerca de 70 % das *Drylands* distribuídas pelo mundo estão desertificadas, o problema se alastra em continentes como África com 73 % de seu território desertificado; Na América do Sul, países como Argentina, Bolívia, Chile, México, Peru e Brasil estão mais susceptíveis a desertificação e segundo projeção da Organização das Nações Unidas (ONU) cerca de 1/5 de toda a produção agrícola destas regiões poderão ser comprometidas devido ao empobrecimento do solo; Ásia, Europa e a Oceania estão enfrentando sérias consequências com a desertificação de suas terras (BAJOCCO, 2011; GISLADOTTIR, 2005; MIAO *et al.,* 2015; SALVATI, 2011; VIEIRA *et al.,* 2015).

O uso e ocupação do solo sem considerar as potencialidades e limitações pode desencadear processos de degradação que implicam em alterações na cobertura vegetal, acarretando em mudanças no balanço de energia entre o solo e atmosfera diminuindo a precipitação e aumentando o risco a desertificação, contudo é preciso melhor entendimento das causas e quantificação dos efeitos responsáveis pela desertificação afim de adotar estratégias efetivas que possam combater e minimizar o risco a desertificação (HAN *et al*., 2021).

A região nordeste é uma das mais afetadas pela desertificação em razão do clima semiárido, caracterizado por baixa precipitação e acentuada pressão antrópica devido ao extrativismo, uso intensivo do solo com práticas agrícolas inadequadas, emprego do fogo, salinização e sobrepastejo. A escassez hídrica e as atividades antrópicas contribuem para a formação de paisagem favorável a ocorrência de processos de desertificação e salinização, reduzindo a produtividade agrícola do solo seguido do aumento da desigualdade social do povo nordestino (VIEIRA *et al.,* 2015).

O semiárido Brasileiro apresenta 06 núcleos de desertificação distribuídos pela região Nordeste, são eles: Gilbués (Piauí); Seridó (Rio Grande do Norte); Cabrobó (PE); Irauçuba Centro Norte, Inhamuns e Jaguaribe (CE), verifica-se que o estado do Ceará é o único com 3 núcleos de desertificação em regiões de relevância econômica, sendo que a área desertificada no estado é de aproximadamente 26.001,96 Km^2, representando mais de 8 % da

área do estado.

As metodologias de monitoramento da desertificação carecem de indicadores que representem os efeitos das mudanças do solo, clima e vegetação e se baseiam em avaliações locais dificultando a extrapolação para grandes áreas, além disso, não se emprega critério estatístico na definição destes indicadores, que dependendo da fonte de coleta apresentam ruídos que comprometem a performance dos modelos (PEREZ – MARIN, *et al*., 2022).

Poucos estudos tem focado no emprego de modelos de regressão múltipla, logística, Redes Neurais e *Support Vector Machine* (SVM) para avaliar o desempenho na predição da suscetibilidade a desertificação em escala local e regional usando índices obtidos via sensoriamento remoto que servem para mensurar indiretamente as mudanças ocorridas na vegetação, clima e solo que são as causas da desertificação.

Diante do contexto, este trabalho fundamenta-se nas seguintes hipóteses: 1) Os modelos paramétricos (Regressão múltipla e Logística) e não paramétricos (Redes Neurais e SVM) são capazes de predizerem a suscetibilidade a desertificação, quantificando os efeitos das mudanças nas condições da vegetação, solo e clima entendidos como causadores da desertificação; 2) partindo da premissa de que os modelos de predição de suscetibilidade a desertificação estão restritos a abordagens locais sem considerar os regimes de precipitações é possível haver diferenças destes quando empregados em nível regional e local e sob condições de seca ou chuva.

2 OBJETIVO GERAL

Avaliar o potencial de desempenho de modelos paramétricos e não paramétricos na predição da suscetibilidade a desertificação em dimensão local e regional com uso de índices que quantificam o efeito de mudanças nas condições de vegetação, clima e solo durante os períodos de 1997 a 2018 nos finais dos períodos secos e chuvosos.

2.1 Objetivos Específicos

Calcular, por meio de imagens de satélites, as mudanças na vegetação, clima, solo e no risco a desertificação através dos índices de NDVI, TGSI, Aridez, suscetibilidade a desertificação e as variáveis de temperatura, albedo, evapotranspiração e precipitação em dimensão local e regional no final do período seco e chuvoso entre 1997 a 2018;

Desenvolver Índice Geométrico de Susceptibilidade a Desertificação (IGSD)

usando o método de ponderação dos índices;

Avaliar o potencial de desempenho dos modelos de Regressão Múltipla (RLM), Regressão Logística (RL), Redes Neurais e *Support Vector Machine* (SVM) na predição do IGSD em dimensão local e regional, conhecendo as limitações de cada modelo.

3 REVISÃO DE LITERATURA

3.1 Desertificação no mundo

A degradação das terras é um problema que afeta extensas áreas pelo mundo, resultando nas perdas de funcionalidades das paisagens devido as diferentes práticas de uso e ocupação do solo através de desflorestamento, aumento de expansão agrícola, sobre pastejo, corte de madeira para uso da construção, salinização entre outros. A perda de funcionalidade da paisagem acarreta redução da produtividade agronômica, prejudicando a segurança alimentar e gerando o caos social com a pobreza e marginalidade, por isso este assunto tem sido tratado como o maior desafio por ambientalistas (MOHAMMED; DENBORA, 2020).

A degradação da paisagem resulta na desertificação que é um processo contínuo caracterizado pela deterioração do solo devido a erosão hídrica e eólica que transportam sedimentos e nutrientes importantes para o desenvolvimento das plantas, afetando a disponibilidade de nitrogênio, fósforo e potássio (AN *et al.,* 2019).

A desertificação é um problema ambiental que atua em 70 % das *drylands* do planeta, afetando diretamente mais de 250 milhões de pessoas pelo mundo e 1 bi indiretamente, os estudos mostram que a cada ano cerca de 12 milhões de hectares de áreas produtivas tornam-se desertificadas, tornando um problema ambiental preocupante e com custos econômicos e sociais relevantes demandando a ordem de mais de 1 bi de dólares a cada ano (EMADODIN *et al.,* 2019).

No continente europeu cerca de 97 milhões de hectares de terras estão afetados pelo processo de degradação do solo, isso corresponde a mais de 33 % de todo território europeu, as regiões mais afetadas são do mar mediterrâneo (Portugal, Espanha, Itália, Grécia, Albânia, Croácia, França, Malta, Eslovênia e Turquia), as principais causas da desertificação são: pressão antrópica, exploração exacerbada dos recursos hídricos, salinização, manejo agrícola inadequado e desflorestamento e fatores ambientais como regime de chuvas, topografia e secas persistentes (SALVIA *et al.,* 2019).

Na África a região mais afetada pela desertificação são áreas próximas ao Sahel

localizado ao sul do deserto do Saara, a alta densidade populacional e pobreza resultam em maior dependência dos recursos naturais, intensificando a degradação das terras africanas tornando-as mais vulneráveis a erosão eólica responsáveis por 55 % de todas as tempestades de areias que lançam sedimentos no oceano atlântico, contribuindo para redução da precipitação e aumento da aridez (WANG *et al.,*2015).

A desertificação aumenta a vulnerabilidade social, indicando maiores susceptibilidades a ocorrência de desastres ou riscos sociais, inicia-se com a exposição a seca, marginalidade ou segregação social e a incapacidade de responder e se mobilizar aos impactos advindos do meio, no Brasil as áreas com maiores vulnerabilidades estão concentradas no Norte e Nordeste (VIEIRA *et al.,* 2020).

3.2 Desertificação no Brasil

As *drylands* mais afetadas pelo processo de desertificação é o semiárido nordestino, caracterizado por apresentar baixa precipitação, altas temperaturas, plantas xerófitas com baixa produção de fitomassa e de aporte de material vegetal a solos de semiárido, ambiente propício para o início dos processos de desertificação, estima-se que cerca 980.711 Km^2 estão desertificados, o problema expandiu-se em oito estados do nordeste, principalmente o Ceará com cerca de 14 % de sua área afetada pelo problema (SOUSA *et al.,* 2012).

De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE) cerca de 22,6 milhões de Brasileiros vivem em áreas de semiárido cuja densidade populacional é de 23 $hab.km^{-2}$, sendo considerado a região de *dryland* mais populosa do mundo. Essa concentração populacional associado com o baixo nível de escolaridade, intensifica a dependência ao meio ambiente, aumentando a pressão populacional sobre estas áreas, desencadeando a degradação pelo desmatamento, caça ilegal, sobre pastejo e práticas agrícolas rudimentares com uso do fogo, a ação conjunta destes fatores aumenta o risco a desertificação (MARTINS *et al.,* 2018).

O processo de degradação não está restrito apenas as áreas de semiárido e sim em áreas de clima úmido através da arenização que afeta mais de 3.000 hectares das terras de 10 municípios do estado do Rio Grande do Sul, formando paisagens arenosas e bastantes instáveis a erosão hídrica e eólica (REICHERT *et al.,* 2016).

As áreas com estágio mais crítico de desertificação no Brasil são definidas como núcleos de desertificação, que estão em expansão e somam 18.740 km^2 de área, atualmente na região nordeste existem 6 núcleos: Gilbués no Piauí; Irauçuba Centro Norte, Inhamuns e Jaguaribe (Ceará); Seridó no Rio Grande do Norte e Cabrobó em Pernambuco (MARIN *et al.,*

2012).

3.3 Desertificação no Nordeste

O estado do Piauí vem tendo destaque no cenário internacional devido a gravidade da desertificação de suas áreas, especialmente no núcleo de Gilbués, localizado no sul do estado, na transição de caatinga com cerrado, este núcleo é representando pelos munícipios de Gilbués, Barreiras do Piauí, Bom Jesus, Corrente, Curimatá, Monte Alegre do Piauí, Redenção do Gurguéia e São Gonçalo do Gurguéia. As causas da desertificação são atribuídas a eventos extremos de precipitação, atividades antrópicas, mineração e sobre pastejo que acarretaram altas taxas de erosão fragilizando os solos e contribuindo para ocorrência de voçorocas (SILVA *et al.,* 2016).

O núcleo de desertificação Irauçuba Centro Norte é constituído pelos municípios de Irauçuba, Canindé, Miraíma e Santa Quitéria, localizado no Ceará com uma área de 9.579,21 Km^2 de extensão e com distribuição pluviométrica irregular, apresentam solos do tipo PLANOSSOLOS e LUVISSOLOS de reduzida capacidade de drenagem, favorecendo a ocorrência de erosão. Outra justificativa é o sobre pastejo em decorrência do rebanho bovino e ovino sobre esta região, dados do IBGE 2006, revelaram que as taxas de lotação para o munícipio de Irauçuba estão 69% acima do recomendado, compactando o solo, resultando em perda por processos erosivos e de nutrientes por escorrimento superficial (FERREIRA *et al.,* 2018).

O núcleo de desertificação dos Inhamuns é constituído por: Arneiroz, Independência e Tauá com uma área de 8.303,46 Km^2 esta região é caracterizada por ter elevados índices populacionais, sobre pastejo, agricultura de subsistência e extrativismo vegetal, além disso, verifica-se baixas precipitações e altas temperaturas, intensificando os processos de desertificação (Ceará, 2010).

O núcleo do médio Jaguaribe é composto por Jaguaretama, Jaguaribara, Morada Nova, Alto Santo e Jaguaribe apresentando uma área de 8.422,77 Km^2, sua formação deve-se a monocultura do algodão e a pecuária. Ambas as atividades contribuíram para a degradação dos solos e a configuração em área desertificada com franca expansão (GUERRA *et al.,* 2012).

No sul de Pernambuco na região compreendida pelos municípios de Cabrobró, Santa Maria da Boa Vista, Orocó, Salgueiro, Belém do São Francisco, Parnamirim, Itacuruba, Petrolina, Floresta, Araripina, Afrânio e Ouricuri, encontra-se o núcleo de desertificação de Cabrobró com 4.960 km^2 de extensão, condições inadequadas do uso da terra juntamente com

fatores climáticos desencadearam a desertificação (MARIN *et al.,* 2012).

Entre os estados do Rio Grande do Norte e Paraíba na região conhecida como Seridó, encontra-se o núcleo de desertificação de mesmo nome, que abrange os municípios de Cruzeta, Currais Novos, Equador, Acari, Parelhas, Caicó, Jardim do Seridó, Ouro Branco, Santana do Seridó e São José de Sabuji. As principais causas da desertificação devem-se ao intenso corte de vegetação, retirada de solo para indústria cerâmica, criação de animais com baixo nível tecnológico e monocultura do algodão que acarretaram na remoção da vegetação e exposição do solo aos processos erosivos seguido do empobrecimento destas áreas (MARIN *et al.,* 2012).

As áreas de semiárido são alvos potenciais para estabelecimento da desertificação, pois a pouca precipitação e baixa capacidade de aporte de material vegetal ao solo contribuem para deficiente cobertura vegetal facilitando a atuação da erosão hídrica e eólica que lixiviam nutrientes e matéria orgânica causando o empobrecimento do ecossistema. O fator antrópico é a principal causa da degradação em todas as áreas desertificadas, devido as maiores fragilidades destas áreas associado com sobre pastejo, desmatamento e práticas agrícolas insustentáveis.

3.4 Modelos de monitoramento da desertificação

O eficiente monitoramento da desertificação deve ser pautado na avaliação em dimensão local e global através do uso de indicadores bem definidos e de fácil interpretação obtidos via sensoriamento remoto; os modelos devem apresentar as variáveis significativas e seus efeitos na desertificação, para conhecer as causas e prover soluções adequadas ao problema (KOBAYASHI, 2020).

Os trabalhos aperfeiçoados por Ferreira (1994) e propostos por Rodrigues (1995) são definidos como os primeiros de identificação da desertificação baseado na hierarquização de níveis críticos de degradação, entretanto os dados empregados no trabalho referem-se a períodos defasados não sendo ideais para estudos atuais, além do uso de indicadores aplicados de forma homogênea e com ponderação baseado em critérios dicotômicos.

Entre as metodologias de identificação da desertificação adotadas pelos órgãos governamentais pode-se destacar a proposta por Matallo Junior (2003) e de diferentes colaboradores, cujos indicadores estão baseados em aspectos físicos, químicos, biológicos e socioeconômicos, tendo como principais desvantagens o emprego de muitos indicadores, problemas de ordem operacional, metodológica e heterogeneidade destes indicadores, dificultando a sua utilização em larga escala espacial e temporal.

Os trabalhos de Vasconcelhos e Matallo (2003) dividem os indicadores em grupos de desertificação e de situação, está metodologia contempla aspectos ambientais (desertificação) e socioeconômicos (situação), as desvantagens estão relacionadas com a escassez de dados das condições do semiárido e que sejam advindas de equipes multidisciplinares (MAIA; COSTA, 2011).

No Brasil umas das metodologias mais empregadas para monitoramento da desertificação é o Sistema de alerta precoce contra a seca e desertificação (SAP) desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE), baseado no modelo MEDALUS (KOSMAS *et al*., 1999), que consiste na combinação de indicadores da desertificação, permitindo identificar áreas susceptíveis a degradação ambiental e com problemas de desertificação.

Outros modelos são utilizados para identificação de áreas suscetíveis a desertificação pela ponderação de indicadores relacionados com a qualidade do solo, clima, vegetação, aspectos socioeconômicos e de uso e ocupação do solo, por exemplo, o MEDALUS (*Mediterranean Desertification and Land Use*) é um modelo desenvolvido por Kosmas *et al*. (1999) que emprega parâmetros relacionados com a qualidade do solo, clima, vegetação e uso e ocupação do solo, identificando áreas vulneráveis a desertificação (*ESAI - Environmentally Sensitive Areas Index)* sendo largamente empregado a muitas décadas.

Contudo a metodologia MEDALUS foi desenvolvida em regiões do mediterrâneo tendo abrangência local, apresentando falhas em abordagens globais devido a heterogeneidade das condições de solo, clima, vegetação e uso e ocupação do solo sendo recomendado melhorias nos modelos para garantir maiores acurácias e precisões (UZUNER; DENGIZ, 2020).

O uso do sensoriamento remoto e dos sistemas de informações geográficas (SIG) permitem melhores abordagens da desertificação, possibilitando monitoramento e modelagem em escala espaço temporal do processo, aperfeiçoando o entendimento e orientando a tomada de decisões por equipes multidisciplinares (CAPOZZI *et al.,* 2018).

A análise univariada da desertificação mostra-se falha na tentativa de identificar as relações entre as mudanças climáticas e os fatores antrópicos. Outro agravante são os métodos atuais de monitoramento da desertificação no Brasil baseados em simples comparações visuais entre mapas temáticos temporais, diversos estudos sugerem o emprego de modelos com múltiplos fatores relacionados a ocorrência da desertificação (BUCKLAND *et al.,* 2019).

As técnicas de inteligência computacional baseada em redes neurais artificiais e SVM podem ser empregadas para modelagem de dados sem conhecimento a priori de sua distribuição estatística, o uso destes modelos permitem manipular grandes bases de dados e ser

mais tolerante a ruídos melhorando o desempenho dos modelos e aumentando a acurácia da classificação (FENG *et al*.,2022).

3.5 Sensoriamento remoto no estudo da desertificação

O sensoriamento remoto é uma técnica de aquisição de imagens de objetos da superfície terrestre a distância pela detecção e medição quantitativa das diferentes interações da radiação eletromagnética com os objetos, constituindo importante método de aquisição permanente de informações para identificar, monitorar, explicar e modelar as mudanças do uso e ocupação do solo em nível espacial e temporal (TELLMAN *et al.,* 2020).

O emprego do sensoriamento remoto permitiu estudos de diversos componentes bióticos e abióticos do meio, garantindo aprimoramento dos dados e ampliando os resultados e as discussões na comunidade científica, como por exemplo, estudo da distribuição espaço temporal de espécies em decorrência das mudanças climáticas, uso e ocupação do solo e degradação (RANDIN *et al.,* 2020); monitoramento de doenças e pestes em cultivos agrícolas (ZHANG *et al.,*2019); estimativa de biomassa e capacidade de estoque de carbono em ecossistemas de savanas (CHAPUNGU *et al.,* 2020); análises do padrão espaço temporal da desertificação considerando múltiplas variáveis, em áreas desertificadas da Mongólia (GUO *et al.,* 2019).

A resolução temporal e a acurácia dos sensores remotos permitem estudos de extensas áreas geográficas através da disponibilidade contínua de imagens a custo reduzido, assegurando o monitoramento e caracterização em larga escala da desertificação. O emprego de sensores remotos para monitoramento da vegetação, textura do solo e o albedo em áreas desertificadas é possível através de operações aritméticas com bandas espectrais, permitindo a sua quantificação, monitoramento e correlação dos diferentes parâmetros ambientais relacionados com a desertificação (GUO *et al*., 2019).

Vários índices e sensores são empregados para estudos de desertificação, como o uso do NDVI e do albedo através do sensor MODIS e TM que permitiu a caracterização de diferentes níveis de desertificação na China durante os anos de 2000 a 2009 (JIANG; LIN, 2018).

O Topsoil Grain Size Index (TGSI) proposto por Liu *et al*. (2018) para monitoramento da textura do solo de áreas desertificadas, permitindo identificar alterações na textura em decorrência da desertificação, enriquecendo as metodologias de abordagem com parâmetros de solo e vegetação; mudanças nas precipitações e evapotranspirações foram

observadas em áreas desertificadas (ZHANG *et al.,* 2020).

O sensoriamento remoto é uma técnica largamente empregada em estudos de desertificação, devido a capacidade de fornecer imagens periódicas da superfície terrestre sobre as diferentes condições de solo, vegetação, clima, temperatura, índice de aridez e etc, entretanto a heterogeneidade da paisagem associado com a mistura espectral do pixel aumenta o ruído da informação reduzindo o desempenho do modelo, para melhorar as estimativas destes modelos e conhecer seus desempenhos em diferentes etapas de simulações é necessário o uso de modelos paramétricos e não paramétricos (FATHIZAD *et al.,* 2018; QI *et al.,* 2019; SALVATI *et al*., 2016).

3.6 Modelos paramétricos

Modelos paramétricos são modelos estatísticos que assumem uma distribuição de probabilidade fazendo suposições sobre esta, em geral, usam a amostra para inferir sobre a média populacional, são modelos mais simples contudo podem ser limitados em razão de nem sempre os dados se aderirem perfeitamente a distribuição normal. Entre os principais modelos paramétricos tem-se: regressão múltipla e logística.

3.6.1 Regressão Múltipla

Modelos de regressão múltipla são bastantes empregados na avaliação e estudos de monitoramento e expansão da desertificação, isso se deve a capacidade destes de indicar quais os fatores são mais importantes na suscetibilidade a desertificação em dimensão local e global, estes modelos dispõem de técnicas estatísticas e computacionais para auxiliar na seleção de variáveis de acordo com a ordem de entrada e importância das variáveis independentes (LIU *et al*., 2021).

A técnica de regressão múltipla foi empregada para seleção de variáveis significativas para monitoramento e avaliação de áreas susceptíveis a desertificação no deserto de Thar na Índia, 23 indicadores foram usados no modelo sendo que 16 apresentaram significância estatística em um modelo com R^2 de 0,83 (SALUNKHE *et al*., 2018).

3.6.2 Regressão Logística

Os modelos de regressão logística diferem-se dos modelos de regressão múltipla em razão dos coeficientes serem calculados pelo método de máxima verossimilhança, cujos

parâmetros são estimados por algoritmos iterativos paramétricos que maximizam a probabilidade de encontrar os coeficientes mais verossímeis para os dados observados. Estes modelos são empregados quando a variável dependente assume valores dicotômicos indicando presença ou ausência da variável estudada. O objetivo desta modelagem é encontrar quais as variáveis independentes que aumentam ou diminuem a probabilidade de ocorrência de um determinado evento (DJEDDAOUI *et al*., 2017; PRADHAN, 2010).

Para avaliação da qualidade do ajuste do modelo de regressão logística é empregado o Pseudo R^2 de Nagelkerke, valores superiores a 0,2 indicam bom ajuste aos dados; As curvas ROC (*Receiver Operating Characteristic*) são úteis para avaliar a capacidade de diagnóstico do modelo baseado na análise gráfica das variações sensibilidade (verdadeiros positivos) e especificidade (falso positivo) para diferentes valores de corte, seus resultados são expressos em função da área sob a curva que quanto mais próximo de 1 melhor é o ajuste (DJEDDAOUI *et al*.,2017; FANJUL – HEVIA *et al*., 2021).

Modelos logísticos foram utilizados para mapeamento da susceptibilidade a desertificação na região de Djelfa na parte central da Argélia, o objetivo foi avaliar e quantificar os fatores que mais contribuíram para a desertificação. O modelo obtido apresentou ROC de 87,8% e Pseudo R^2 Nagelkerke de 0,53 e mostrou que o NDVI, áreas de pastagens, fatores climáticos e geomorfológicos apresentaram fortes correlações com a desertificação (DJEDDAOUI *et al*., 2017).

3.7 Modelos Não Paramétricos

Modelos não paramétricos são modelos estatísticos que não fazem suposições sobre os parâmetros da distribuição, testam suas hipóteses com base em informações coletadas nas amostras e podem trabalhar com dados que se aderem a qualquer distribuição, sendo mais tolerantes a ruídos e valores extremos. Dentre os principais exemplos de modelos não paramétricos tem-se: Redes Neurais e SVM.

Dados obtidos por sensoriamento remoto para monitoramento e avaliação da desertificação não se aderem a distribuição normal e, portanto, não atendem simultaneamente aos pressupostos dos modelos paramétricos, produzindo resultados inconsistentes e reduzindo as acurácias dos modelos, demandando o emprego de modelos não paramétricos como redes neurais e SVM (FENG *et al*., 2021).

3.7.1 Redes Neurais Artificiais

Redes neurais artificiais são modelos computacionais não paramétricos baseados na estrutura do cérebro humano, são constituídas de uma rede complexa de neurônios interconectados que possui ampla capacidade de aprendizado, associação e generalização capaz de descrever padrões em dados, aproximar funções matemáticas, identificar e modelar a não linearidade entre as variáveis de entradas, isso devido a versatilidade que estes modelos possuem de se ajustarem ao conjunto de dados (AZARI *et al*., 2016).

As redes do tipo MLP (*multilayer perceptron*) são arquiteturas de redes neurais caracterizadas por apresentarem uma ou mais camadas intermediárias (*Hidden Layer)* entre a camada de entrada (*Input layer*) e a camada de saída (*Output layer*). A camada de entrada refere-se aos dados de entrada nas redes neurais, em seguida são extraídas as características dos conjuntos de dados na *Hidden Layer* e produzido uma resposta, o quão bom é esta resposta depende do aprendizado da rede que ocorre na fase de treinamento por um algoritmo de aprendizado *backpropagation* que consiste no ajuste iterativo dos coeficientes (pesos sinápticos) até que a resposta obtida apresente o menor erro possível em relação as entradas (WANG *et al*., 2020).

A função de ativação sigmoide logística serve para fazer o mapeamento não linear entre as entradas e saídas, devido ao uso das vantagens de propriedades matemáticas destas funções como completa diferenciabilidade, tornando a rede com maiores graus de flexibilidade, possibilitando uma representação mais adequada do fenômeno estudado, além disso estas funções estão envolvidas no processo de aprendizado de uma rede, pois a atualização dos pesos demanda o gradiente local do erro e a derivada da função de ativação (MIGUEZ *et al*., 2014).

As diferentes arquiteturas e flexibilidade das redes neurais permitem identificar e explorar relacionamentos não lineares em dados de alta dimensionalidade, esse conjunto de benefícios possibilita diversas aplicações em dados de sensoriamento remoto, como na classificação e segmentação de imagens de satélite (BOULILA *et al*., 2021); uso e ocupação do solo (GHAYOUR *et al*., 2021); Identificação de áreas suscetíveis a desastres ambientais (NHU *et al*., 2020); salinidade do solo (WANG *et al*., 2020); estudo da erosão do solo (GHOLAMI *et al*., 2021) e em mapeamento e classificação de áreas desertificadas (PI *et al*., 2021).

Redes neurais artificiais foram utilizadas na predição da desertificação com base em diversas variáveis na região central da Itália, os resultados mostraram baixos erros e alto R^2 = 0,9667 (coeficiente de determinação) e que as variáveis de uso e ocupação do solo e a precipitação foram as responsáveis pela ocorrência de desertificação na região (RAMPONE; VALENTE,2018).

Estudos feitos por Pi *et al*. (2021) concluíram que o uso de redes neurais aumentou a qualidade de imagens de drone para identificação de áreas desertificadas em pastagens, permitindo a construção de modelos de classificação para monitoramento da desertificação e eventuais projetos de restauração ecológica.

Redes neurais tem capacidade de analisar dados de alta dimensionalidade por meio da conexão de unidades de processamento (neurônio) que introduzem não linearidades as variáveis de entrada, além disso, por serem modelos não paramétricos dispensam o conhecimento a priori da distribuição estatística dos dados, permitindo melhor representação do conhecimento extraído (ALIPOIR *et al*., 2017).

3.7.2 Support Vector Machine (SVM)

Os modelos de *Support Vector Machine* (SVM) apresenta-se como um tipo de técnica de aprendizado de máquina desenvolvido por Vapnik (1998) capaz de resolver problemas de classificação e regressão em grandes bases de dados e evitar os problemas de otimização (CERVANTES *et al*., 2020).

Inicialmente as aplicações do SVM eram voltadas na resolução de problemas de classificação binária para dados linearmente separáveis, contudo devido a fundamentação teórica, capacidade de generalização e uso de funções kernel, este algoritmo tem sido largamente aplicado em diferentes campos de conhecimento sendo extensamente usado para trabalhar com dados não linearmente separáveis (JALAL *et al*., 2020).

Existem diversas aplicações do SVM em diferentes campos de conhecimento, como, em mapeamento da cobertura vegetal, uso e ocupação do solo, modelagem da paisagem, estudos de qualidade da água e do ar e quantificação das propriedades do solo, a robustez do modelo associado à sua capacidade de lidar com *outliers* o torna bastante eficiente na modelagem de diferentes tipos de dados (HAFEEZ *et al*., 2019).

O SVM foi empregado para classificação e mapeamento de áreas afetadas por processos de desertificação em 3 diferenças regiões da China, como variáveis de entrada foram utilizadas o NDVI, declividade e elevação, o resultado da classificação foi o nível de desertificação que variou entre não desertificado até extremamente desertificado, a performance do classificador SVM se deu através de coeficiente Kappa e os resultados mostraram valores de Kappa de 0,7917 a 0,8083 indicando que o SVM foi efetivo para o mapeamento da desertificação (XU *et al*., 2012).

O SVM foi empregado para quantificar os efeitos das atividades humanas e

variações climáticas na cobertura vegetal na planície *Loess Plateau* na China, para isso foram empregadas dados da temperatura do ar e precipitação de 1986 a 2006 como variáveis independentes e o NDVI como variável resposta, o SVM foi empregado para construção de modelos de calibração para obtenção de parâmetros que referem-se ao período impactado e ao não impactado, com isso pode-se simular o NDVI para ambos os períodos e quantificar as mudanças do mesmo provenientes de mudanças climáticas e de atividades antrópicas usando os dados da simulação do SVM. Os resultados mostraram que as mudanças climáticas têm maior efeito sobre o NDVI (59,3%) do que as atividades antrópicas (40,7%) (HUANG *et al*., 2020).

4 METODOLOGIA

4.1 Áreas de estudo

Neste trabalho, a abordagem da vulnerabilidade a desertificação levou em consideração a dimensão local e regional das unidades estudadas. A dimensão local refere-se à aplicação dos modelos paramétricos e não paramétricos em cada unidade territorial da região de Irauçuba Centro Norte (Miraíma, Irauçuba, Santa Quitéria e Canindé). A dimensão regional é aplicação dos modelos paramétricos e não paramétricos em Irauçuba Centro Norte.

Essa delimitação, tem por objetivo avaliar o desempenho dos modelos paramétricos e não paramétricos em nível local (cada unidade territorial) e regional (Irauçuba Centro Norte). A localização geográfica, caracterização pedológica, climática e geomorfológica de Irauçuba Centro Norte e de cada unidade territorial estão apresentadas nos tópicos 5.1.1 e 5.1.2, respectivamente.

4.1.1 Irauçuba Centro Norte (Dimensão Regional)

Irauçuba Centro Norte localiza-se na porção central do Ceará (3°35’ e 4°44’ S e 39° 38’ e 39°63’ W) apresentando 9.579,21 km^2 de área (Figura 1).

Figura 1 - Localização de Irauçuba Centro Norte (regional)

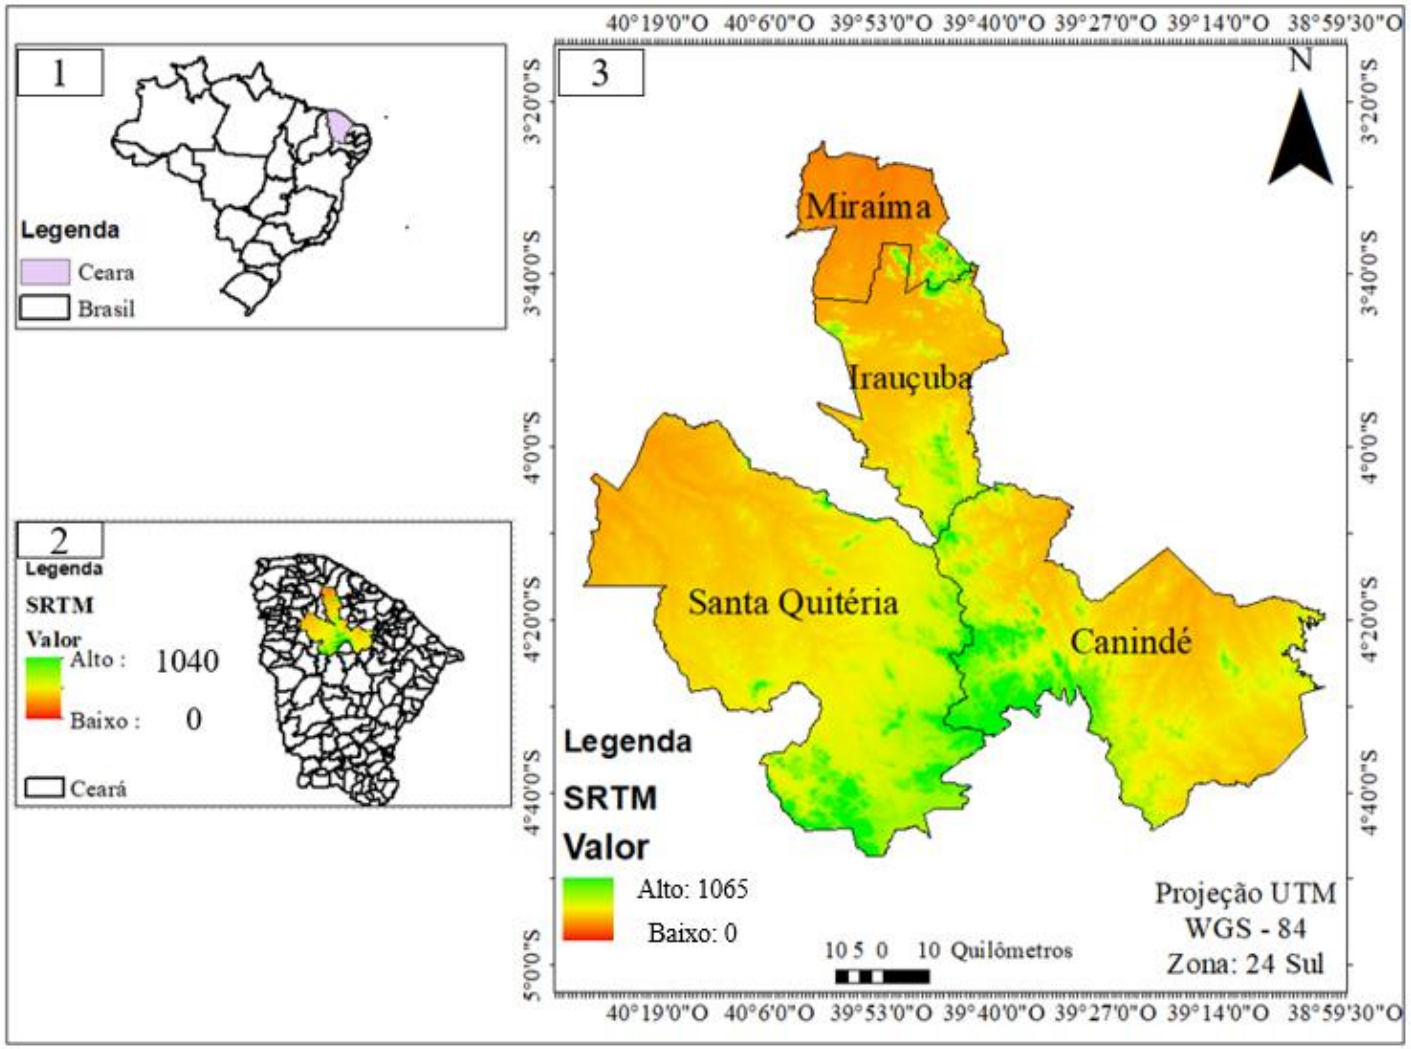

Fonte: Elaboração Própria; 1: República Federativa do Brasil; 2: Estado do Ceará e a região de Irauçuba Centro Norte (ICN); 3: ICN.

Irauçuba Centro Norte apresenta vegetação do tipo Caatinga Arbustiva de cobertura herbácea, com potencial forrageiro, favorecendo a pecuária extensiva que ocupa 67% da área, contribuindo para degradação e intensificação da erosão (SOUSA *et al*., 2012). De acordo com a classificação de Köppen o núcleo apresenta clima do tipo Bsh'w, semiárido quente, alta variabilidade de precipitação, temperatura média anual de 26,3°C e precipitação inferior a 500 mm.

Nos aspectos geomorfológicos, Irauçuba Centro Norte é delimitado pelos Sertões e Serras. Os sertões compreendem os sertões de Sobral, Canindé, Santa Quitéria, Miraíma e de Irauçuba, apresentando superfícies pedi planadas a moderadamente dissecadas com precipitações entre 560 a 850 mm, apresentam NEOSSOLOS Litólicos (em baixas vertentes e cristas residuais), LUVISSOLOS (colinas rasas), PLANOSSOLOS e NEOSSOLOS Flúvicos (em fundos de vales).

As áreas de serras são: Serras das Matas, Rosário, Machado, Uruburetama e de Baturité com precipitações entre 550 a 900 mm, apresentam classes de solos do tipo ARGISSOLOS Vermelhos Amarelos, NEOSSOLOS Litólicos e Flúvicos (FUNCEME, 2015).

4.1.2 Unidades Territoriais (Dimensão Local)

Miraíma está localizado em latitude de 3°34' S e longitude 39°58' W, com área de 699,59 Km^2, tem clima tropical quente semiárido com precipitações médias de 897,5 mm e temperaturas médias entre 26°C e 28°C, apresenta vegetação do tipo caatinga arbustiva aberta e está inserida em unidades geomorfológicas dos sertões Miraíma/Aracatiaçu e na vertente meridional da serra da Uruburetama.

As áreas dos sertões de Miraíma/Aracatiaçu apresentam superfícies moderadamente dissecadas e precipitações entre 700 a 800 mm, quanto a pedologia verifica-se LUVISSOLOS (colinas rasas), NEOSSOLOS Litólicos (baixas vertentes), PLANOSSOLOS e NEOSSOLOS Flúvicos para fundos de vales; uso e ocupação baseia-se em pecuária extensiva e agroextrativismo.

A vertente meridional da serra da Uruburetama apresenta superfície dissecada e precipitações entre 890 a 900 mm, os solos são do tipo ARGISSOLOS VERMELHOS AMARELOS e Neossolos Litólicos (FUNCEME, 2015; IPECE, 2009).

Canindé está localizado em latitude de 4°21' S e longitude 39°18' W, com área de 3.218,42 Km^2, tem clima tropical quente semiárido com precipitações médias de 756,10 mm e temperaturas médias entre 26°C e 28°C, apresenta vegetação do tipo caatinga arbustiva aberta,

densa e floresta subcaducifólia tropical pluvial e está inserida em unidades geomorfológicas dos sertões de Canindé constituído por superfícies moderadamente dissecadas com precipitações superiores a 600 mm; e de Serras do Machado e de baixa vertente ocidental da Serra de Baturité com superfícies dissecadas e precipitações entre 580 a 740 mm. Nos sertões de Canindé verifica-se LUVISSOLOS, NEOSSOLOS Litólicos e NEOSSOLOS Flúvicos; uso e ocupação baseia-se em pecuária extensiva e agroextrativismo; Nas áreas das Serras do Machado e de baixa vertente ocidental da Serra de Baturité verifica-se associação de ARGISSOLOS Vermelhos Amarelos, NEOSSOLOS Litólicos e Flúvicos (FUNCEME, 2015; IPECE, 2009). A localização espacial das unidades territoriais de Miraíma e Canindé podem ser vistos nas Figuras 2 e 3, respectivamente.

Figura 2 - Localização Espacial de Miraíma

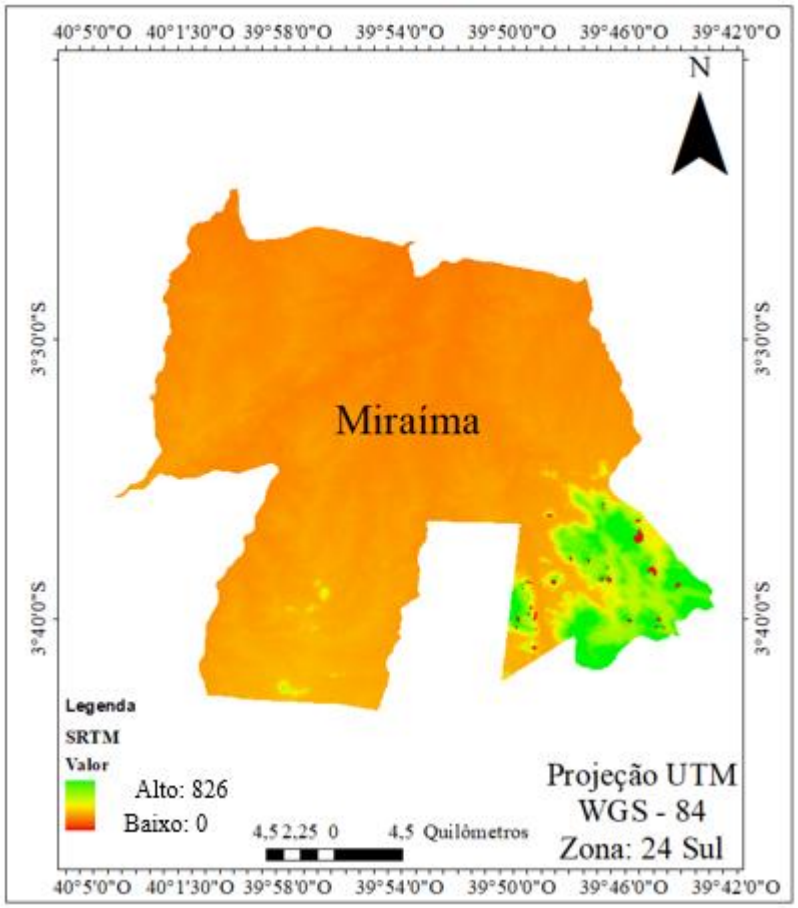

Fonte: Elaboração Própria.

Figura 3 - Localização Espacial de Canindé

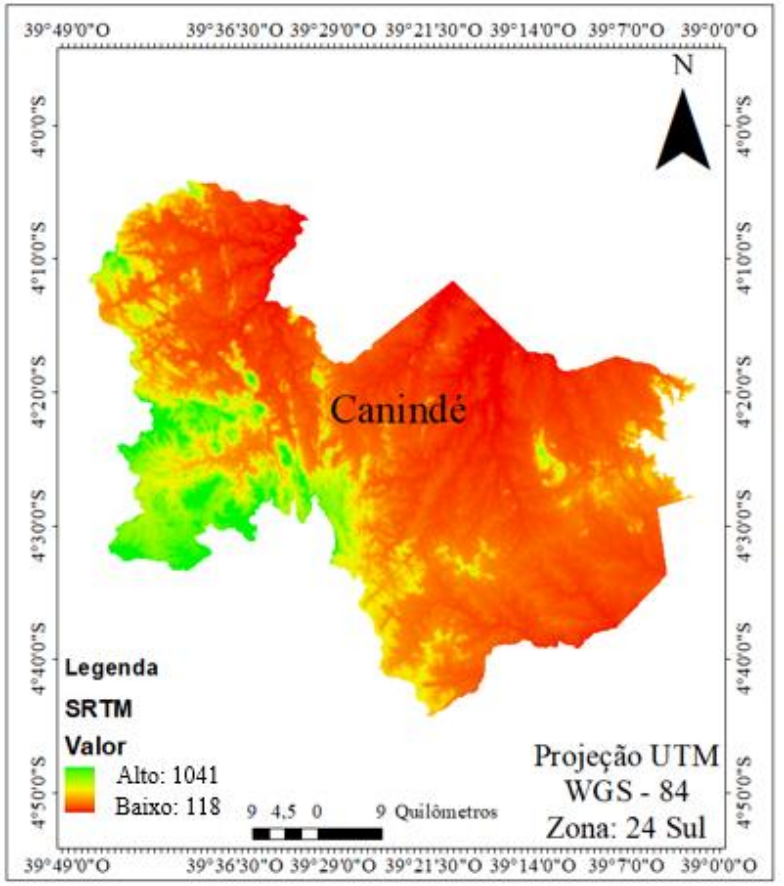

Irauçuba está localizado em latitude de 3°44’ S e longitude 39°47’ W, com área de 1.461,22 km^2, tem clima tropical quente semiárido com precipitações médias de 539,50 mm e temperaturas médias entre 26°C e 28°C, apresenta vegetação do tipo caatinga arbustiva aberta, e está inserida em unidades geomorfológicas dos sertões de Irauçuba com superfícies pedi planadas a moderadamente dissecadas e precipitações entre 600 a 890 mm; e da vertente meridional da serra da Uruburetama apresentando superfícies mais dissecadas com precipitações entre 890 a 900 mm. Nos sertões de Irauçuba verifica-se LUVISSOLOS (colinas rasas do sertão), NEOSSOLOS Litólicos (Baixas vertentes), ARGISSOLOS (altas vertentes), PLANOSSOLOS e NEOSSOLOS Flúvicos (fundos de vales); uso e ocupação baseia-se em pecuária extensiva e agroextrativismo; Nas áreas da vertente meridional da serra da Uruburetama verifica-se associação de ARGISSOLOS Vermelhos Amarelos e NEOSSOLOS Litólicos (FUNCEME, 2015; IPECE, 2009).

Santa Quitéria está localizado em latitude de 4°19’ S e longitude 40°09’ W, com área de 4.260,50 Km^2, tem clima tropical quente semiárido com precipitações médias de 799,80 mm e temperaturas médias entre 26°C e 28°C, apresenta vegetação do tipo Caatinga Arbustiva Aberta, Floresta Caducifólia Espinhosa e Floresta Subcaducifólia Tropical Pluvial; está inserida em unidades geomorfológicas dos sertões de Santa Quitéria, apresentando superfícies moderadamente dissecadas a pedi planadas com precipitações entre 650 a 700 mm; os domínios das Serras do Machado e vertente setentrional das Serras das Matas apresentam superfícies dissecadas e precipitações superiores a 740 mm. Nos sertões de Santa Quitéria verifica-se LUVISSOLOS, NEOSSOLOS Litólicos, PLANOSSOLOS e NEOSSOLOS Flúvicos revestidos por caatinga degradada em áreas de pecuária extensiva e agroextrativismo; nas áreas de serras do Machado e vertente setentrional das Serras das Matas verificam-se associações de ARGISSOLOS Vermelhos Amarelos, LUVISSOLOS, NEOSSOLOS Litólicos e Flúvicos revestidos por caatinga arbórea e mata seca (FUNCEME, 2015; IPECE, 2017).

A localização geográfica de Irauçuba e Santa Quitéria podem ser vistos nas Figuras 4 e 5, respectivamente.

Figura 4 - Localização Espacial Irauçuba

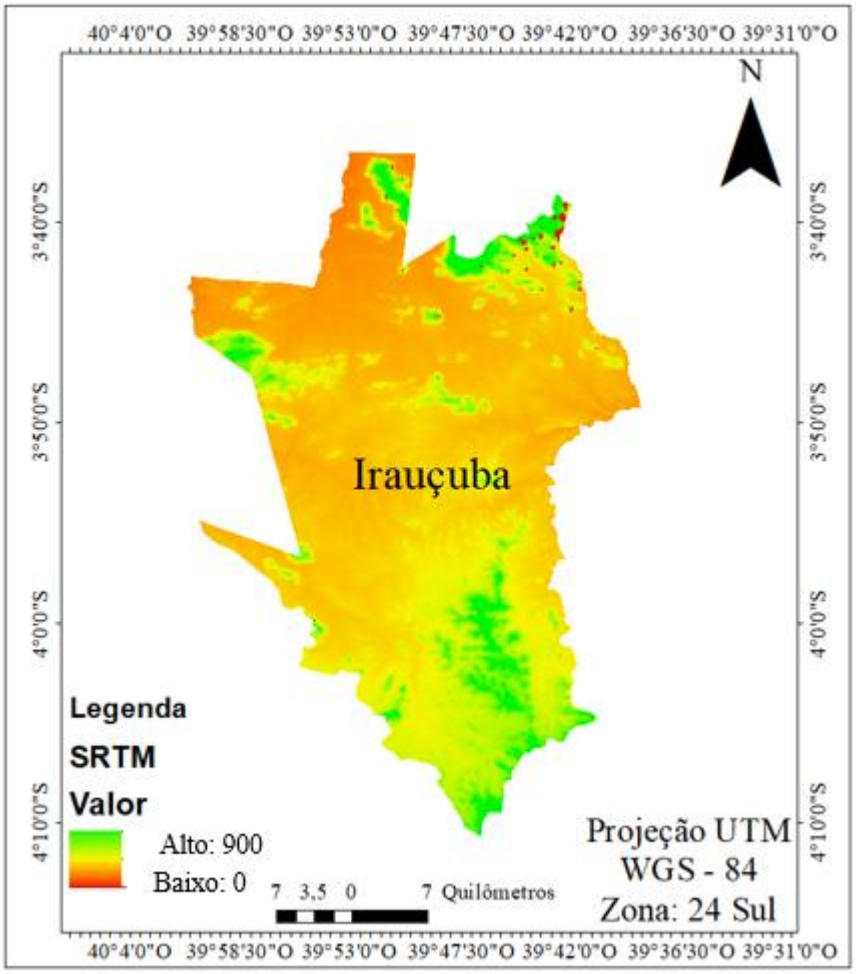

Figura 5 - Localização Espacial Santa Quitéria

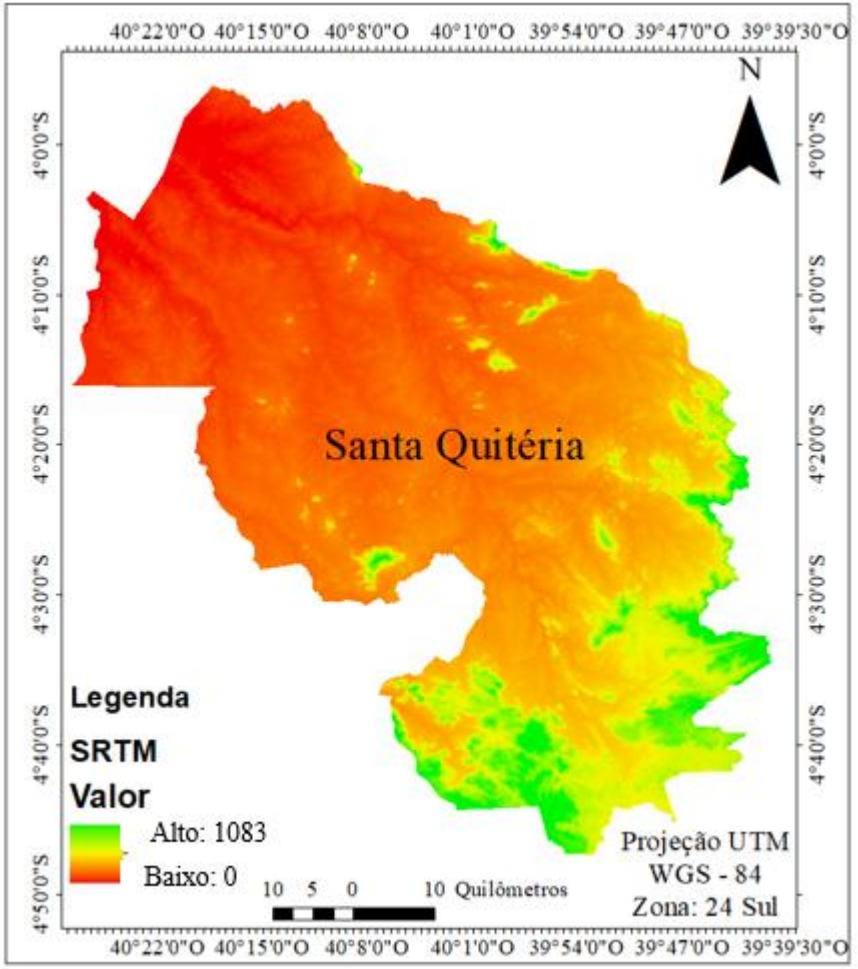

Fonte: Elaboração Própria.

4.2 Aquisição e processamento de imagens

As imagens dos satélites Landsat 05 (sensor TM), Landsat 07 (sensor ETM+) e Landsat 08 (Sensor OLI e TIRS) referentes as órbitas/pontos 217/063, 218/062 e 218/063 foram obtidas da plataforma da United States Geological Survey (USGS). As unidades locais de Irauçuba e Santa Quitéria e a regional de Irauçuba Centro Norte tiveram suas imagens submetidas ao procedimento de normalização radiométrica pela equalização do histograma afim de realçar os alvos da imagem e reduzir o efeito de linha de mosaico. Foi empregado como critério de seleção de imagens a cobertura por nuvens e as precipitações observadas em períodos secos e chuvosos. Os anos da série temporal entre 1997 a 2018 foram subdivididos em: FC (Final Chuvoso) e FS (Final Seco) (Tabela 1).

Tabela 1 - Períodos de imagens adquiridos da série Landsat 05, 07 e 08

Satélite/Sensor	Período
Landsat 05/ *Thematic Mapper*	1997FC
	1998FC
	1999FC
	2000FS
	2000FC
	2001FC
	2003FS
	2004FS
	2004FC
	2005FS
	2005FC
	2006FS
	2006FC
	2007FC
	2008FS
	2008FC
Landsat 07/ *Enhaced Thematic Mapper Plus*	2011FS
	2011FC
	2012FS
	2012FC
Landsat 08/ *Operational Land Imager - Termal Infrared Sensor*	2013FC
	2014FC
	2015FC
	2016FC
	2017FC
	2018FC

Fonte: USGS; FS: Final do Período Seco; FC: Final do Período Chuvoso.

As imagens obtidas foram reprojetadas para zona 24 SUL e DATUM WGS – 84, no software Envi® 4.8 utilizando o algoritmo *layer stracking* e submetidas ao processo de correção atmosférica usando o módulo Flaash do Envi® 4.8 através do modelo de transferência radioativa- MODTRAN (ADLER - GOLDEN *et al.,*1999), equação 1. Optou-se pelo emprego deste algoritmo na correção atmosférica em razão do aprendizado proporcionado pela parametrização deste sendo importante para fins didáticos da disciplina de sistemas de informações geográficas.

$$L = \frac{A\rho}{1-\rho_e S} + \frac{B\rho_e}{1-\rho_e S} + L *_A \quad (1)$$

em que, ρ é a reflectância do pixel, ρ_e é a média de reflectância dos pixels mais próximos, S é o albedo atmosférico, L*a é radiância refletida pela atmosfera, A e B são os coeficientes que dependem das condições atmosféricas locais.

4.3 Cálculo dos Índices

Os índices foram calculados para as unidades territoriais (dimensão local) e Irauçuba Centro Norte (dimensão regional) para os períodos apresentados na Tabela 1. A quantificação dos índices serve para mensurar indiretamente o efeito de mudanças da vegetação, solo e clima frente a ação antrópica desencadeadora da desertificação. Empregaram-se recursos do Arcmap como calculadora *raster* e álgebra de mapas.

4.3.1 NDVI, TGSI, Albedo

O NDVI foi proposto por Rouse *et al.* (1974), sendo calculado pela equação 2:

$$NDVI = \frac{(Infravermelho\ próximo - Vermelho\ Visível)}{(Infravermelho\ próximo + Vermelho\ Visível)} \quad (2)$$

em que, o infravermelho próximo compreende a região espectral entre 760 nm a 900 nm e a do vermelho visível entre 630 nm a 690 nm.

O TGSI proposto por Xiao *et al.* (2006) foi calculado pela equação 3:

$$\text{TGSI} = \frac{(Vermelho\ Visível - Azul\ Visível)}{(Vermelho\ Visível + Azul\ Visível + Verde\ Visível)} \quad (3)$$

em que, o azul visível varia entre 450 nm a 520 nm; o verde visível de 520 nm a 600 nm e vermelho visível de 630 nm a 690 nm.

O albedo foi quantificado usando as etapas do algoritmo SEBAL proposto por Bastiaanssen *et al.* (1998), a primeira delas foi a calibração radiométrica usando a equação 4:

$$L_\lambda = a_i + \left(\frac{b_i - a_1}{255}\right) \times ND \ \ (\text{Wm}^{-2}\ \text{sr}^{-1}\mu\text{m}^{-1}) \quad (4)$$

em que, a e b são as radiâncias espectrais mínimas e máximas (Tabela 2); ND é a intensidade do pixel (número digital – número inteiro de 0 a 255); i corresponde às bandas (1, 2,..., 7) do satélite Landsat 5 – TM e L_λ a radiância em $Wm^{-2}\ sr^{-1}\mu m^{-1}$.

Na Tabela 2 estão contidos os parâmetros de calibração usados no cálculo do albedo para Landsat 05 e 07.

Tabela 2 - Descrição de bandas do sensor TM

Bandas	**Comprimento de Onda (µm)**	**Coeficientes de Calibração (W/m² sr.µm)**		**Irradiância Espectral (W/m².µm)**
		A	**B**	
1 (azul)	0,45 – 0,52	-1.520	193.000	1957
2 (verde)	0,53 – 0,61	-2.840	365.000	1829
3 (vermelho)	0,62 – 0,69	-1.170	264.000	1557
4 (IV-próximo)	0,78 – 0,79	-1.510	221.000	1047
5 (IV-médio)	1,57 – 1,78	-0.370	30.200	219,3
6 (IV-termal)	10,4 – 12,5	1.238	15.303	-
7 (IV-médio)	2,10 – 2,35	-0.150	16.500	74,52

Fonte: USGS; A: Radiância mínima; B:Radiância máxima.

Para determinação do albedo usando o sensor OLI, foram utilizados os parâmetros de calibração para Landsat 08, (Tabela 3).

Tabela 3 - Descrição de bandas do OLI

Bandas	Comprimento de Onda (µm)	Coeficientes de Calibração (W/m² sr.µm)	
		a	B
1 – Costeira	0,433 - 0,453	-64,14586	776,7692
2 – Azul	0,450 - 0,515	-65,68613	795,4211
3- Verde	0,525 - 0,600	-60,52922	732,97382
4 – Vermelho	0,630 - 0,680	-51,04165	618,08478
5 - Infravermelho – próximo	0,845 - 0,885	-31,23494	378,23706
6 - SWIR 1	1,560 - 1,660	-7,76785	94,06412
7 - SWIR 2	2,100 - 2,300	-2,61818	31,70464
8 – Pancromática	0,500 - 0,680	-57,76509	699,50189
9 – Cirrus	1,360 - 1,390	-12,20732	147,82362
10 - Termal 1	10,3 - 11,3	0,10033	22,0018
11 - Termal 2	11,5 - 12,5	0,10033	22,0018

Fonte: USGS; A: Radiância mínima; B:Radiância máxima.

Com as radiâncias calculadas determinou-se a reflectância no topo da atmosfera (TOA) usando a equação 5 proposta por Chander e Markham (2003):

$$\rho_{\lambda i} = \frac{\pi \times L_{\lambda I}}{K_{\lambda I} \times cosZ \times D_r} \quad (5)$$

em que, $L_{\lambda i}$ é a radiância espectral de cada banda, $k_{\lambda i}$ é a irradiância solar espectral de cada banda no topo da atmosfera, Z é o ângulo zenital solar e d_r é o inverso do quadrado da distância relativa Terra-Sol (em unidade astronômica – UA), obtido pela equação 6:

$$d_r = 1 + 0{,}033 \times \cos\left(DJ \frac{2\pi}{365}\right) \quad (6)$$

em que, DJ é o dia juliano e o argumento da função co-seno em radianos. O ângulo zenital solar foi obtido através do arquivo de metadados das imagens adquiridas.

Finalmente para determinação do albedo planetário σ_{TOA} fez uso da equação 7:

$$\alpha_{toa} = \Sigma(\rho_{\lambda i} \times \omega_{\lambda 1}) \quad (7)$$

Os coeficientes de cada banda foram baseados nos valores encontrados na literatura, conforme (Tabela 4).

Tabela 4 - Coeficientes usados no cálculo do albedo

Satélite	Banda 1	Banda 2	Banda 3	Banda 4	Banda 5	Banda 7
Landsat 05	0,293	0,274	0,233	0,157	0,033	0,011

Fonte: SEBAL.

Os valores contidos na Tabela 4 foram usados na equação 8, para o Landsat 05, 07 e 08:

$$\alpha_{toa} = (0{,}293 \times B_1) + (0{,}274 \times B_2) + (0{,}233 \times B_3) + (0{,}157 \times B_4) + (0{,}033 \times B_5) + (0{,}011 \times B_7) \quad (8)$$

4.3.2 Temperatura

A Temperatura de Superfície foi estimada a partir da banda termal dos satélites Landsat 05, 07 e 08 e foi levado em consideração a temperatura de brilho calculada em função da radiância detectada pelo sensor, das emissividades de cada pixel em função dos valores do índice de área foliar (IAF) e dos efeitos atmosféricos que atenuam a radiância do termal (SILVA; SOUZA, 2005).

A radiância termal ou a temperatura de brilho foi determinada usando o inverso da equação de Planck, em que a radiância $L_{\lambda I}$ (W m^{-2} sr^{-1} μm^{-1}) foi obtida por meio da conversão do número digital variando ente 0 a 255, de acordo com a equação 9:

$$L_{\lambda I} = L_{(\lambda)\min} + \left[L_{(\lambda)\max} - L_{(\lambda)\min}\right] Q_{(ND)} / Q_{\max} \quad (9)$$

sendo, $L_{\lambda\ é}$ a radiância espectral ($W/m^2.sr.\mu m$); $L_{(\lambda)\min}$ é a radiância espectral mínima; $L_{(\lambda)\max}$ é a radiância espectral máxima; $Q_{(\max)}$ é o número digital máximo que pode ser assumido para um sensor de 8 bits, ou seja, 255; $Q_{(ND)}$ é o nível de cinza de cada pixel.

A temperatura de brilho com correção da emissividade se deu com a equação 10, proposta por Chander e Markhan (1986). Os valores das constantes térmicas da banda termal foram de K_1 = 607,76 W m^{-2} $sr^{-1}\mu m^{-1}$ e K_2 = 1260,56 K.

$$T_b = \frac{K_2}{\ln\left(\frac{\varepsilon 0 * K_1}{L_\lambda}\right) + 1} \quad (10)$$

em que, T_b é a temperatura de brilho em Kelvin; K_1 e K_2 são parâmetros de calibração; L_λ é a radiância espectral ($W/m^2.sr.\mu m$); ε_{NB} é a emissividade de cada pixel estimada pela equação 11.

$$\varepsilon_{nb} = 0{,}97 + 0{,}00331 \times IAF \quad (11)$$

O IAF necessita da determinação do *Soil Adjusted Vegetation Index* (SAVI), cujos valores variam entre 0 a 1 e é útil para minimizar os efeitos de brilho do solo, o SAVI foi calculado pela equação 12:

$$SAVI = \frac{\rho_{inf} - \rho_v}{\rho_{inf} + \rho_{r+L}} * (1 + L) \quad (12)$$

sendo, ρ_{inf} a reflectância na banda do infravermelho próximo; ρ_v a reflectância na banda do vermelho; L é o fator de ajuste em função da cobertura vegetal, adotado o valor de 0,5 indicando vegetação intermediária. O índice de área foliar e dado pela razão entre a área foliar de toda a vegetação por unidade de área utilizada por essa vegetação, sendo necessário quantificá-lo como estudos de biomassa vegetal, sendo determinado pela equação 13, proposta por Allen *et al*. (2002).

$$IAF = \frac{\ln\left(\frac{0{,}69 - SAVI}{0{,}59}\right)}{0{,}91} \quad (13)$$

As temperaturas em Kelvin foram diminuídas por 273,15 obtendo os dados em Celsius (C°). O método para determinação da Temperatura de Superfície foi baseado no algoritmo SEBAL (*Surface Energy Balance Algorithm for Land*) proposto por Bastiaanssen *et al.* (1998).

4.3.3 Precipitação

As precipitações de 12 postos pluviométricos distribuídos pela região de Irauçuba Centro Norte foram fornecidas pela FUNCEME, estes dados fazem referência a série histórica de 1997 a 2018. Devido a não uniformidade da distribuição espacial dos postos pluviométricos foi empregado o método de Thiessen para determinação das áreas de influências dos postos

pluviométricos e quantificação das médias ponderadas de precipitações considerando a área de influência de cada posto.

Inicialmente foi feito *rasterização* das médias ponderadas de precipitações, em seguida, foi criado um grid de pontos com distâncias regulares sobre o raster de precipitação e escolhidos aleatoriamente 100 pontos com precipitações médias conhecidas, criando um arquivo chamado "*Z_points_ano*" que foi usado como entrada no algoritmo IDW para geração das precipitações em pontos desconhecidos, com base na equação 14 proposta por Marcuzzo *et al*. (2011):

$$\text{Precipitação} = \frac{\sum_{i=1}^{n} \frac{Z_i}{hij^{\beta}}}{\sum_{i=1}^{n} \frac{1}{hij^{\beta}}} \quad (14)$$

em que, n é a quantidade de pontos próximos com precipitações médias conhecidas usados nas estimativas dos pontos de precipitações desconhecidas; Zi é o valor de precipitação associado ao ponto i; h_{ij} é a distância do ponto i ao j e β refere-se ao parâmetro de potência igual a 2.

4.3.4 Índice de Aridez

O índice de aridez foi calculado tendo por base os valores de evapotranspiração potencial (ETP) e o índice de calor. Os dados de temperatura máxima média, mínima média e de umidade relativa média foram da estação 82392 – Sobral - CE com coordenadas -3,73 de latitude sul; -40,33 de longitude oeste e altitude de 109,63 metros. A estação foi escolhida devido a proximidade com área de estudo. Foram feitos downloads dos dados referentes aos períodos de 1997 a 2018 em formato txt.

Os dados de temperatura média do ar obtidos a partir da média entre a temperatura máxima e mínima e a umidade relativa do ar referente a cada um dos anos de estudo foram inseridos no cálculo do índice de calor (ºC) conforme a metodologia proposta por Steadman (1979), equação 15:

$$IC = -42{,}379 + 2{,}04901523*T + 10{,}14333127*UR - 6{,}83783*10^{-3}*T^2 - 5{,}481717*10^{-2}*UR^2 + 1{,}22874*10^{-3}*T^2*UR + 8{,}5282*10^{-4}*T*UR - 1{,}99*10^{-6}*T^2*UR^2 \quad (15)$$

em que, T é a temperatura do ar (ºC) e UR é a umidade relativa do ar (%) e IC é o índice de calor em (ºC).

Os dados de índice de calor foram utilizados no cálculo do parâmetro *a* na equação 16:

$$a = =6{,}75*10^{-3}*IC - 7{,}711*10^{-5}*IC + 1{,}792*10^{-2}*IC + 0{,}492 \quad (16)$$

O parâmetro *a* foi utilizado na equação do cálculo da evapotranspiração potencial mensal realizado através da equação 17:

$$ETP = 16{,}2[10*T/IC]^{a} \quad (17)$$

em que, ETP é a evapotranspiração potencial mensal, IC é o índice de calor e T é a temperatura média condensada do ar, o valor de a é determinado em função do IC (índice de calor). Por último o índice de aridez foi calculado pela equação de Thornthwaite (1948), conforme a equação 18:

$$IA = P_r / ETP \quad (18)$$

em que, IA é o índice de aridez, P_r é a precipitação e ETP é a evapotranspiração potencial mensal. Com os dados de índice de aridez foram construídos os mapas no Arcmap versão 9.4 ®.

4.3.5 Evapotranspiração Horária (ETh)

A evapotranspiração horária ou instantânea foi calculada nas imagens da série Landsat 05, 07 e 08 através do SEBAL (*Surface Energy Balance Algorithms for Land*) baseado na metodologia proposta por Bastiaanssen (1995). Este algoritmo é dividido em 4 partes: Saldo de Radiação (Rn), fluxo de calor no solo (G), Calor Sensível (H) e fluxo de calor latente (LE) todas estas componentes são dadas em W. m^{-2}.

4.3.5.1 Saldo de Radiação (Rn)

Para cômputo do saldo de radiação (Rn) foram calculados a calibração radiométrica, reflectância, albedo, NDVI, SAVI, IAF, emissividades, temperatura de superfície, radiação de onda longa emitida, radiação de onda curta incidente e radiação de onda longa incidente. O saldo de radiação foi determinado pela equação 19:

$$Rn = R_{s\downarrow} - \alpha R_{s\downarrow} + R_{L\downarrow} - RL_{\uparrow} - (1 - \varepsilon_0) R_{L\downarrow} \quad (19)$$

em que, Rn é o saldo de radiação; $R_{s\downarrow}$ refere-se a radiação de onda curta incidente; α: Albedo de superfície (adimensional); $R_{L\downarrow}$ é a radiação de onda longa incidente; $R_{L\uparrow}$ é radiação de onda longa emitida; ε_0 é a emissividade de superfície para cada pixel (Adimensional).

4.3.5.2 Fluxo de Calor no Solo (G)

O fluxo de calor do solo é a quantidade de energia do saldo de radiação (Rn) utilizada para aquecimento do solo, seu cálculo foi feito com a equação 20 proposta por Bastiaanssen (2000):

$$G = [T_s (0{,}0038\alpha + 0{,}0074\alpha) (1\text{-}0{,}98\times NDVI^4)]R_n \quad (20)$$

em que, G é o fluxo de calor no solo; T_s é a temperatura de superfície (°C); α refere-se ao albedo de superfície (adimensional); NDVI é o índice de vegetação por diferença normalizada (adimensional); R_n é o saldo de radiação.

4.3.5.3 Fluxo de Calor Sensível (H)

O fluxo de calor sensível refere-se a taxa de calor que é transferida para o ar por processos de convecção e condução, sua estimativa leva em consideração processos iterativos relacionados com a resistência aerodinâmica (R_{ah}) e a diferença de temperatura de superfície (dT), o processo é finalizado quando as diferenças de R_{ah} e dT mostram-se constantes, neste trabalho foram necessárias 5 iterações para alcançar a estabilidade, todos as etapas da iteração foram realizadas no Arcmap versão 10.7 ®.

Para estimativa inicial do H levou-se em consideração que a atmosfera estava em condições neutras e seu cômputo se deu com a equação 21:

$$H = (\rho \times C_p \times dt) / R_{ah} \quad (21)$$

em que, H é o fluxo de calor sensível; ρ é massa específica do ar (adimensional); C_p refere-se ao calor específico do ar (1004 Jkg^{-1} K^{-1}); dt é a diferença de temperatura entre duas alturas (Z_2 e Z_1) e R_{ah} é a resistência aerodinâmica ao transporte de calor ($s.m^{-1}$).

Em seguida procedeu-se com o cômputo da rugosidade inicial de acordo com a equação 22 sugerida por Allen *et al.* (2002):

$$Z_{om\ inicial} = 0{,}12h \quad (22)$$

em que, h é a altura média da vegetação em metros, neste estudo considerou-se h de 2,0 metros.

Em seguida calculou-se a velocidade de fricção (u*) na hipótese de atmosfera neutra, usando a equação 23:

$$u_* = k\ u_2 / \ln (Z_2 / Z_{om\ inicial}) \quad (23)$$

em que, K é a constante de von karman (0,41); u_2 é a velocidade do vento ($m.\ s^{-1}$) na altura (z_2) de 2,0 metros. Com as informações de rugosidade inicial ($Z_{om\ inicial}$) e a velocidade de fricção em condição de atmosfera neutra (u_*), calculou-se a velocidade do vento a uma altura de 100 metros (u_{100}), usando a equação 24:

$$u_{100} = u_* \ln (100/ Z_{om\ inicial}) / k \quad (24)$$

Para condição de atmosfera neutra, a resistência aerodinâmica inicial foi calculada pela equação 25:

$$R_{ah\ inicial} = \ln (Z_2/ Z_1) / u_* k; \quad (25)$$

em que, $R_{ah\ inicial}$ é a resistência aerodinâmica inicial em ($m.s^{-1}$); Z_2 e Z_1 são as alturas de 0,1 e 2,0 metros respectivamente. A diferença de temperatura próxima a superfície dT (C°) para cada pixel foi determinada pela relação linear entre dT e a temperatura de superfície, equação 26:

$$dT = a + b * \text{Temperatura de superfície} \quad (26)$$

em que, a e b são coeficientes obtidos através da determinação do pixel quente e frio. Para determinação do pixel frio e quente levou-se em consideração o NDVI, Albedo e temperatura de superfície no referido pixel, neste caso para pixel frio a sua determinação se deu com valores de NDVI elevado (Acima de 0,50), Albedo baixo (0,05) e temperatura baixa (22 C°).

Para determinação do pixel quente utilizaram-se áreas de solo exposto com altos valores de albedo (>0,10), baixo NDVI (<0,30) e altas temperaturas (34 C°), neste caso o fluxo de calor sensível para o pixel quente H_{quente} foi calculado pela equação 27:

$$H_{quente} = R_n - G \quad (27)$$

O uso da equação 27 para determinação do fluxo de calor sensível para pixel quente serve apenas como valor inicial do processo iterativo, pois neste início de cálculo não foi levado em consideração as condições turbulentas que afetam a atmosfera e a resistência aerodinâmica, para resolver este problema foi aplicado a teoria de similaridade de Monin – Obukhov para todos os pixels da área de estudo, conforme equação 28:

$$L = (\rho\, C_p\, u_* Ts) / k*g*H \quad (28)$$

em que, C_p é o calor específico do ar (1004 $Jkg^{-1}\ K^{-1}$); u* é a velocidade de fricção ($m.s^{-1}$); Ts é a temperatura de superfície em Kelvin; K é a constante de Von Karman (0,41) (adimensional) e g constante gravitacional (9,81 $m.s^{-2}$).

Os valores de L podem ser:

L<0 (condição de instabilidade);

L>0 (condição de estabilidade);

L=0 (condição neutra).

Para este experimento os valores de L indicaram (condição de instabilidade), neste caso empregaram-se as equações 29, 30, 31, 32, 33 e 34 para cálculo do transporte de momentum (Ψ_m) e de calor (Ψ_h) propostas por Paulson (1970) e Webb (1970).

$$\Psi_{m200} = 2 \ln (1+ X_{(200m)}^2) / 2 – 2\text{arctg}(X_{(200m)}) + 0,5 * \pi \quad (29)$$

$$\Psi_{h(2m)} = 2 \ln (1+ X_{(2m)}^2) / 2 \quad (30)$$

$$\Psi_{h(0,1m)} = 2 \ln (1+ X_{(0,1m)}^2) / 2 \quad (31)$$

Onde:

$$X_{(200m)} = (1-16*200/L)^{0,25} \quad (32)$$

$$X_{(2m)} = (1-16*2/L)^{0,25} \quad (33)$$

$$X_{(0,1m)} = (1-16*0,1/L)^{0,25} \quad (34)$$

em seguida procedeu-se com o cálculo da velocidade de fricção u* ($m.s^{-1}$) pela equação 35:

$$u_* = (u_{200} * k) / \ln(200/Z_{om}) - \Psi_{m(200m)} \quad (35)$$

em que, u_{200} é a velocidade do vento a 200 metros ($m.s^{-1}$); Z_{om} é coeficiente de rugosidade para cada pixel (m) e $\Psi_{m\ (200\ m)}$ é a correção da estabilidade para transporte de momentum a 200 metros. Com o cálculo do $u_{*\ corrigido}$ obteve-se o valor corrigido de resistência aerodinâmica ao transporte de calor R_{ah} ($s.m^{-1}$) de acordo com a equação 36:

$$R_{ah} = (\ln (z_2/ z_1) - \Psi_{h(Z2)} + \Psi_{h(Z1)}) / u_{*\ corrigido} . k \quad (36)$$

em que, z_2 é de 2,0 metros, z_1 foi de 0,1 metros e $\Psi h(z2) + \Psi h(z1)$ são as correções da estabilidade para o transporte de calor a 2,0 metros e 0,1 metros, respectivamente.

Após o cômputo do R_{ah} retorna-se para equação 21 iniciando a iteração 2, ao todo foram necessárias 5 iterações para que as diferenças de R_{ah} e dT fossem constantes.

4.3.5.4 Fluxo de Calor Latente (LE)

O fluxo de calor latente refere-se à quantidade de energia proveniente do saldo de radiação que é destinada aos processos evaporativos, após o cálculo das componentes Saldo de radiação (Rn), fluxo de calor de solo (G) e fluxo de calor sensível (H) procedeu-se com o cálculo do fluxo de calor latente em $W.m^{-2}$ usando a equação 37:

$$LE=Rn–G–H \quad (37)$$

4.3.5.5 Evapotranspiração Horária (ETh)

Com o cálculo do fluxo do calor latente se procedeu com o cômputo da evapotranspiração horária ET_h, usando a equação 38:

$$ET_h=(3600*LE)/\lambda \quad (38)$$

em que, ETh refere-se a evapotranspiração horária ($mm\ h^{-1}$); LE é o fluxo de calor latente ($W.m^{-2}$); λ indica o calor latente de vaporização da água ($2{,}45x10^6\ J.kg^{-1}$), 3600 é um fator de conversão de variável instantânea em variável horária. Todos os passos do SEBAL foram realizados no Arcgis versão 10.7.

4.4 Construção do Índice Geométrico de Suscetibilidade a Desertificação

O índice Geométrico de Suscetibilidade a Desertificação (IGSD) foi adaptado da metodologia MEDALUS proposta por Kosmas *et al*. (2018), equação 39:

$$IGSD=[\prod_{n=1}^{7} S_i]^{\frac{1}{7}} \quad (39)$$

em que, n é o número de variáveis usadas para determinação da suscetibilidade a desertificação; S_i é o peso atribuído ao valor de índice de acordo com o nível que este favorece

a suscetibilidade a desertificação e ∏ é produto dos pesos de cada índice.

Para construção do IGSD de Irauçuba Centro Norte (Dimensão Regional) criou-se malha regular de 649 pontos amostrais sobre os *rasters* de NDVI, TGSI, Albedo, Evapotranspiração, Temperatura, Precipitação e Índice de Aridez calculados para os períodos secos e chuvosos de 1997 a 2018. Com a ferramenta do Arcmap "*Extrair Múltiplos Valores para Pontos*" foi possível capturar a informação destes índices para todos os pontos amostrados.

Foi adotado a mesma metodologia para cada unidade territorial, porém com diferentes quantidades de pontos amostrados, sendo de 50 pontos amostrais para Miraíma; 215 pontos para Canindé; 96 pontos para Irauçuba e 288 pontos para Santa Quitéria. Deste modo cada ponto amostrado carregava os valores dos 7 índices calculados para a Irauçuba Centro Norte e para cada uma das unidades territoriais. As ponderações dos índices foram feitas tomando por base o trabalho de Xu *et al*. (2019) e Sharma *et al*. (2021), (Tabela 5).

Tabela 5 – Ponderações dos índices usados no IGSD

Critério	Índice	Intervalos	Unidades	Peso
Vegetação	NDVI	<=0,3	Adimensional	2
		0,3<NDVI<=0,4		1,5
		NDVI>0,4		1,0
Solo	TGSI	-0,01<=TGSI<=0	Adimensional	1,0
		TGSI>0		2,0
	Albedo	<=0,1	Adimensional	1
		0,1<Albedo<=0,20		1,5
		Albedo>0,20		2
Climáticos	Índice de Aridez	IA<0,1	Adimensional	2
		0,10<=IA<1,0		1,5
	Precipitação	Precipitação<=150	mm	2
		150<Precipitação<=300		1,5
		Precipitação>300		1
	Evapotranspiração	Evapotranspiração<0,41	mm/h	1
		0,41<=Evapotranspiração<=0,55		1,5
		0,55<Evapotranspiração<1		2
	Temperatura	Temperatura<25,3C°	Celsius	1
		25,3C°<=Temperatura<=41,55C°		2

Fonte: Adaptado de Xu *et al*. (2019) e de Sharma *et al*. (2021).

Com o peso associado ao valor de cada índice foi calculado o IGSD pela média geométrica dos pesos (IGSD - Convencional), os valores de IGSD foram classificados com base em intervalos de ESAI *(Environmentally Sensitive Areas Indez)* propostos por Uzuner e Dengiz

(2020) (Tabela 6).

Tabela 6 - Valores de ESAI usados como referência para classificação do IGSD

Classe	ESAI (Intervalo)
Desertificado	>1,54
Crítico	1,38 - 1,53
Frágil	1,23 – 1,37
Potencial	1,17 – 1,22
Não Afetado	<1,17

Fonte: UZUNER; DENGIZ, 2020.

4.5 Modelos Paramétricos

A regressão múltipla e logística são exemplos de modelos paramétricos que foram aplicados nos finais dos períodos secos e chuvosos entre 1997 a 2018, com objetivo de predizer o IGSD, identificar as variáveis mais relevantes e sua contribuição no aumento da média do IGSD e no risco a desertificação, respectivamente.

4.5.1 Regressão Múltipla

O modelo de regressão múltipla para predição do IGSD usando os 7 índices, foi obtido pelo modelo matricial, equação 40:

$$Y_j = \chi_j \beta_j + \varepsilon_j \quad (40)$$

em que, Y_j é um vetor de dimensão n x 1 que representa os valores do j – ésimo IGSD para os n elementos da amostra; X_j é uma matriz de dimensão n x (K_j +1) composta pelas variáveis de NDVI, TGSI, Albedo, Evapotranspiração, Temperatura, Precipitação e Índice de Aridez associado ao j-ésimo IGSD; β_j é um vetor de parâmetros estimados pelos mínimos quadrados [β_{0j}, ... β_{Kj}] (j=1....., ρ) e ε_j é o vetor de erros aleatórios de dimensão n x 1.

A contribuição de cada índice no aumento ou redução da média do IGSD, deu-se com o coeficiente $\beta_{padronizado}$, equação 41:

$$\beta_{padronizadoYX} = \frac{\beta_{não\ padronizado} \cdot S_x}{S_y} \quad (41)$$

em que, $\beta_{padronizadoYX}$ é o coeficiente β padronizado pelo desvio padrão; $\beta_{não\ padronizadoYX}$ é o coeficiente β não padronizado obtido no modelo de regressão; S_x indica o desvio padrão do índice; S_y o desvio padrão do IGSD.

A contribuição do índice foi obtido a partir do coeficiente β padronizado, sendo calculado pela equação 42:

$$Efeito\ IGSD\ (\%)_X = \left(\beta_{padronizadoyx} \cdot S_y \middle| IGSD_{médio}\right) \cdot 100 \quad (42)$$

em que, efeito IGSD $(\%)_x$ é o valor em percentual de contribuição do coeficiente β padronizado na média do IGSD; $IGSD_{médio}$ é a média do IGSD do período do modelo de treinamento; $\beta_{padronizadoYX}$ é o coeficiente β padronizado pelo desvio padrão; S_y é o desvio padrão do IGSD. A inserção dos dados no modelo de regressão múltipla e análises posteriores foram feitas no software estatístico SPSS.

4.5.2 Regressão Logística

O modelo logístico foi empregado para identificar e quantificar os índices que aumentam ou diminuem o risco a desertificação (DJEDDAOUI *et al*.,2017). Sua fórmula está representada pela equação 43:

$$\rho = \frac{1}{1+e^{-\alpha+\sum \beta_i X_i}} \quad (43)$$

em que, ρ é a probabilidade de ocorrência da desertificação podendo variar entre 0 e 1; α é intercepto do modelo; β_i são os coeficientes estimados pela máxima verossimilhança; X_i representam os índices calculados. Os valores de probabilidades preditos (ρ) foram divididos em 5 classes (Tabela 7).

Tabela 7 - Classificação da suscetibilidade a desertificação

Classe	Intervalo
Não Afetado	0,00 – 0,14
Baixa Suscetibilidade	0,15 – 0,36
Moderada Suscetibilidade	0,37 – 0,60
Alta Suscetibilidade	0,61 – 0,83
Extrema Suscetibilidade	0,81 – 1,00

Fonte: Djeddaoui *et al*. (2017).

Foram empregados os Odds ratio das variáveis explicativas para quantificação da probabilidade de risco a desertificação, equação 45:

$$p = \frac{\text{chance}}{1+\text{chance}} \tag{45}$$

em que, p indica a probabilidade calculada para o odds ratio do índice; Chance é o odds ratio resultado da exponencialização do coeficiente β do referido índice.

4.6 Modelos Não Paramétricos

Nos tópicos que se seguem tem-se as redes neurais e o SVM empregados com o objetivo de emular a resposta do risco a desertificação em função das diferentes condições de vegetação, clima e solo.

4.6.1 Redes Neurais

Redes neurais artificiais são modelos computacionais não paramétricos que se baseiam na estrutura do cérebro humano. Neurônios interconectados possui ampla capacidade de aprendizado, associação e generalização (AZARI *et al*., 2016).

A predição do IGSD usando a rede neural do tipo *Multilayer Perceptron* foi feita com base na equação 46:

$$y_k = \varphi_{(.)}\left(\sum_{j=1}^{n} w_{jk} * x_m\right) + b_k \tag{46}$$

em que, y_k é o valor de IGSD predito pela rede neural MLP; $\sum_{j=1}^{n} wjk$ é um combinador linear referente aos sinais das entradas multiplicados pelos pesos sinápticos

associados a cada índice; x_m refere-se ao vetor de variáveis de entradas; b_k é um peso adicional geralmente de valor +1 associado a uma variável x_1 igual a 1; φ(.) é a função de ativação sigmoide logística que tem por finalidade introduzir não linearidade ao potencial de ativação tornando a rede capaz de modelar conjuntos linearmente separáveis e não separáveis.

Foi utilizado o rstudio para definição dos parâmetros como números de neurônios, taxas de aprendizados, tipo de função de ativação e porcentagem dos dados usados nas etapas de treinamento e validação. Empregou-se o algoritmo Garson com o objetivo de ranquear as variáveis na suscetibilidade a desertificação.

4.6.2 Máquinas de Vetores de Suporte

O modelo de *Support Vector Machine* (SVM) foi desenvolvido por Vapnik (1998) e busca a separação do conjunto de dados através de um hiperplano de separação ótima. A fórmula do SVM usada na predição do IGSD pode ser vista na equação 47:

$$s(_{X_i}) = (\sum_{i=1}^{T} \mathrm{w}_i \varphi\,(X_i) + b) \tag{47}$$

em que, $s(_{X_i})$ é o valor de IGSD predito pelo modelo; w_i é o vetor de pesos ótimos obtidos para os dados de treinamentos; φ é uma função kernel de base radial que introduz não linearidade ao modelo; X_i São os 7 índices calculados; b é o bias ótimo obtido dos dados de treinamentos. Foi utilizado o rstudio para definição dos parâmetros de kernel, cost e gamma, assim como as porcentagens de dados usados nas etapas de treinamento e validação.

4.7 Avaliações e métricas de desempenhos dos modelos

Todos os modelos foram avaliados nas etapas de treinamento, validação e teste. O treinamento refere-se a construção dos modelos empregando os índices como entrada para predição do IGSD - Convencional, nesta etapa foram empregados 649 pontos amostrais de Irauçuba Centro Norte; 50 pontos amostrais para Miraíma; 215 pontos para Canindé; 96 pontos para Irauçuba e 288 pontos para Santa Quitéria tanto em finais de períodos secos e chuvosos entre 1997 a 2018.

O critério de escolha do modelo de treinamento da regressão múltipla, Redes Neurais e SVM foi R^2 e RMSE calculados pelas equações 48 e 49, respectivamente:

$$R^2=\frac{\sum_i^n(Y_{estimado}-Y_{médio})}{\sum_i^n(Y_{observado}-Y_{médio})} \quad (48)$$

e

$$RMSE=\sqrt{\frac{\sum_{i=1}^n(Y_{estimado}-Y_{observado})}{N}} \quad (49)$$

em que, $Y_{estimado}$ são os valores de IGSD estimados pelo modelo; $Y_{médio}$ é a média dos valores de IGSD - Convencional; $Y_{observado}$ são os valores de IGSD – Convencional; N é o número de pontos amostrais.

Para o modelo logístico empregou-se o pseudo R^2 de Nagelkerke calculado pela equação 50:

$$R^2_{Nagelkerke}=\frac{1-\left(\frac{L_0}{L_1}\right)^{\frac{2}{n}}}{1-(L_0)^{\frac{2}{n}}} \quad (50)$$

em que, L_0 é o modelo somente com intercepto; L_1 é o modelo com os 7 índices; N é o número de pontos amostrais. A curva ROC (*Receiver Operatining Characteristic*) foi obtido a partir das probabilidades preditas pelo modelo logístico versus o status da variável dependente, podendo ser: (0) não desertificado e (1) desertificado. Este procedimento foi feito no SPSS. As Taxas de acertos para cada modelo logístico foram calculadas com base na equação 51:

$$\text{Taxa de Acerto (\%)} =\frac{VP+VN}{P+N} \quad (51)$$

em que, VP são os verdadeiros positivos e referem-se aos pontos desertificados e que foram identificados como tal pelo modelo; VN são os verdadeiros negativos e referem-se aos pontos não desertificados e que foram classificados como tal pelo modelo; P é total de pontos positivos para desertificação e N é o total de pontos negativos para a desertificação.

Os valores de R^2 e $R^2_{Nagelkerke}$ indicam o quanto da variância da variável dependente

é explicada pelo modelo, quanto mais próximo de 1 melhor é o modelo, contudo em relação ao $R^2_{Nagelkerke}$ as exigências são menores, autores como Clark e Hosking (1986) e Djeddaoui *et al*. (2017) consideram que modelos logísticos com R^2 Nagelkerke superiores a 0,20 mostram-se adequados para predição da variável dependente.

A fase de validação consistiu no uso dados de pontos amostrais não empregados na etapa de treinamento do modelo, para isso, delimitou-se malha regular de pontos amostrais com espaçamentos diferentes da malha usada para o treinamento. Os pontos amostrais usados na fase de validação para Irauçuba Centro Norte foram de 615 pontos; 66 pontos para Irauçuba; 46 para Miraíma; 200 pontos amostrais para Canindé e 279 pontos para Santa Quitéria.

Na fase de validação foram removidos os pontos que apresentam outliers com o objetivo de melhorar o desempenho dos modelos de regressão múltipla e logística.

Para os modelos de redes neurais e SVM as métricas de R^2 e RMSE correspondem ao conjunto de treinamento/validação, pois, na parametrização destes modelos é necessário estabelecer dados de treinamento e validação.

Os modelos de regressão múltipla e logística que apresentaram maiores R^2 nas etapas de treinamento e validação foram submetidos a etapa de teste, usando os índices significativos para os modelos e obtidos em imagem de Landsat 08 referentes ao período de 2018FC. Este período foi utilizado em razão de ser o último ano da série temporal estudada. Para os modelos de redes neurais e SVM foram utilizados os parâmetros e a arquitetura do modelo que apresentou maior R^2. Com estes parâmetros e arquitetura definidos, empregaram-se todos os índices calculados em 2018FC, procedendo – se com o processamento dos dados pelos neurônios até produzir estimativas de IGSD com maior R^2 e menor RMSE.

As predições de IGSD referente aos dados de 2018FC (fase de teste) foram comparadas com o IGSD de 2018FC obtido pela média geométrica dos índices (IGSD – Convencional), estes resultados estão contidos em tabelas e referem aos modelos de regressão múltipla, redes neurais e SVM. Para a regressão logística o desempenho do modelo foi avaliado com base em valores de curvas ROC e de taxas de acertos.

As predições de IGSD feitas pelos modelos com os dados de testes de 2018FC correspondem a predições discretas de IGSD, sendo necessário o emprego de interpoladores para conversão destas predições em contínuas.

4.8 Construção e validação do Mapa de IGSD

Foram empregados interpoladores para espacialização das predições de IGSD

referente aos dados de testes de 2018FC, o melhor interpolador foi aquele que apresentou menor RMSE. Após a espacialização do IGSD, este foi classificado pixel a pixel de acordo com o nível de suscetibilidade a desertificação obtido pelas refletâncias dos índices em cada pixel, em seguidas foram selecionadas amostras de treinamento para inserção no classificador de máxima verossimilhança (MAXVER). O mapa final de IGSD foi avaliado com base em acurácia global e coeficiente Kappa obtido da matriz de confusão produzida pelo classificador. A acurácia global e o coeficiente kappa foram calculados pelas equações 52 e 53, respectivamente.

$$\text{Acurácia Global (\%)} = \frac{\sum_i^k Pii}{N} \quad (52)$$

em que, P_{ii} são os elementos da diagonal principal da matriz de confusão; N é o número total de pontos analisados.

$$\text{Kappa} = \frac{P_0 - Pe}{1 - P_e} \quad (53)$$

em que, P0 é a acurácia global; Pe é a concordância randômica.

Para cada modelo foram quantificados as médias de erros de omissão (MEO) que se referem a quantidades de pixels da classe que foram erroneamente agrupados em outras; e médias de erros de comissão (MEC) que indicam a quantidade de pixels que foram indevidamente alocados na classe, ambos os erros são calculados levando em consideração a matriz de confusão. As fórmulas podem ser vista*s* nas equações 54 e 55, respectivamente.

$$\text{Erros de Omissão (\%)} = \frac{X_{I+} - X_{II}}{X_{I+}} \quad (54)$$

e

$$\text{Erros de Comissão (\%)} = \frac{X_{+I} - X_{II}}{X_{+I}} \quad (55)$$

em que, X_{ii} são os elementos da diagonal principal da matriz de confusão; X_{i+} são os elementos marginais da linha da matriz de confusão na classe de observação; X_{+i} referem-se aos elementos marginais da coluna da matriz de confusão na classe de observação.

4.9 Validação em Campo

O mapa produzido por cada um dos modelos para Irauçuba Centro Norte e para cada uma das unidades territoriais, foi comparado com o mapa de zoneamento ecológico econômico elaborado pela Funceme (2014) na escala de 1:300.000 que apresenta além do zoneamento, informações de geomorfologia e uso e ocupação do solo para as comunidades mapeadas pelos modelos. A avaliação da assertividade do modelo em campo se deu pelo emprego da equação 56:

$$\text{MTAC (\%)} = (NCC/\text{NTC}) / \text{N} \quad (56)$$

em que, MTAC indica a média de taxa de acerto de campo em percentual; NCC é o número de comunidades classificadas corretamente e NTC o número total de comunidades. O melhor modelo para suscetibilidade a desertificação será aquele que apresentar as maiores métricas de acurácia global e kappa, maior número de classe identificadas, menores MEO, MEC e maiores MTAC.

4.10 Metodologia do trabalho de tese

A metodologia deste trabalho pode ser resumida pelo fluxograma, cujas etapas estão numeradas de 1 a 4, Figura 6.

Figura 6 - Metodologia do Trabalho de Tese

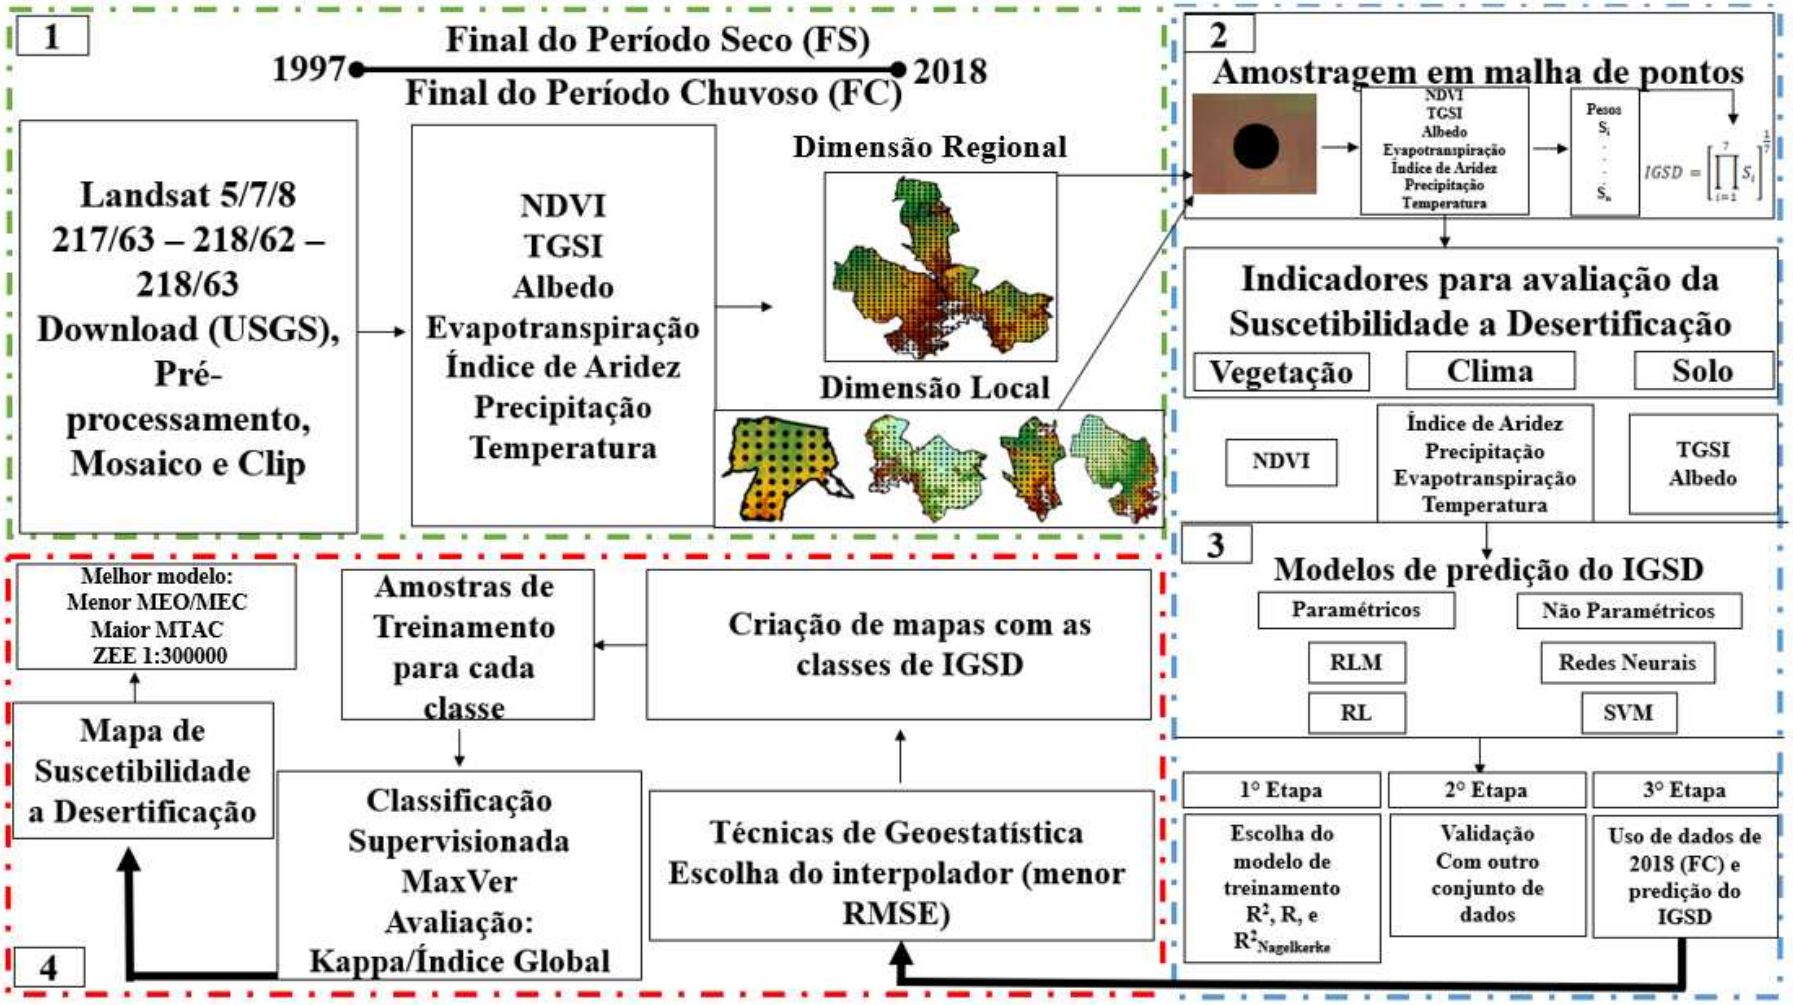

Fonte: Elaboração Própria; MEO: médias de erros de omissão (%); MEC: médias de erros de comissão (%); MTAC: médias de taxa de acerto de campo; ZEE: Zoneamento Ecológico Econômico. Escala de 1:300000; 1: Aquisição e processamento das imagens em dimensão regional e local; 2: atribuições de pesos aos índices e cálculo do IGSD; 3: modelos usados na predição do IGSD; 4:interpolação, contrução dos mapas, classificação supervisionada, mapa final de IGSD e escolha do modelo.

A etapa 1 refere-se ao processo de aquisição, processamento e quantificação dos índices em dimensão regional e local usando imagens referentes aos finais de períodos secos e chuvosos entre 1997 a 2018 dos satélites Landsat 05, 07 e 08. Nesta etapa foi aplicado correção geométrica, atmosférica, reprojeção para zona 24 S, mosaicamento e clipagem pela área de Irauçuba Centro Norte e de cada uma das unidades territoriais, todos os processos descritos na etapa 1 foram realizados no ENVI 4.5.

A etapa 2 refere-se as ponderações dos índices para cálculo do IGSD pela média geométrica dos 7 índices calculados. A etapa 3 indica que todos os índices calculados foram usados como variáveis explicativas (X) e o IGSD como variável dependente (Y). Em todos os períodos foram aplicados todos os modelos com objetivo de identificar o melhor modelo de treinamento e de validação para predição do IGSD; os melhores modelos (regressão múltipla e logística) e arquiteturas (redes neurais e SVM) foram submetidas as etapas de testes usando índices calculados em uma imagem de 2018FC. O passo 4 mostra o emprego de técnicas de interpolações, criação de mapas para seleção de amostras de treinamento baseado na informação espectral delimitada pela extensão de cada classe e inserção no classificador MAXVER cujos resultados foram os mapas de IGSD avaliado mediante acurácia global, kappa, média de erros de omissões e de comissões e confronto com o mapa de zoneamento ecológico econômico elaborado pela Funceme (2014) na escala de 1:300.000.

5 RESULTADOS E DISCUSSÕES

5.1 Miraíma

5.1.2 RLM, RL, Redes Neurais e SVM

Os melhores modelos de RLM, regressão logística e redes neurais foram obtidos para os períodos de 2005FC, 2000FS e 2000FC, respectivamente. As variáveis significativas e as contribuições nas médias do IGSD e no risco a desertificação pode ser vistos na Tabela 8.

Tabela 8 – Índices e contribuições nas médias do IGSD e no risco a desertificação em Miraíma

Local	RLM		RL	Redes Neurais
	Variáveis	**IGSD %**	**Risco (%)**	**(Garson Algoritmo)**
Miraíma	NDVI	-4*	$1{,}3788.10^{-26}$*	17
	TGSI	NS	NS	6
	Albedo	3,6*	NS	12
	Evapotranspiração	5,2*	99,99*	18
	Temperatura	5,1*	74,05*	35
	Índice de Aridez	-2,6*	NS	1
	Precipitação	NS	NS	8

Fonte: Elaboração Própria; * p – value<0,05; NS: não significativo – p – value>0,05; RLM – 2005FC: R^2: 0,795; RL - 2000FS: R^2 Nagelkerke: 0,777; Redes Neurais - 2000FC: R^2: 0,9998; sinal (-) indica redução em escala de percentual na média do IGSD.

O NDVI e o Índice de Aridez apresentaram coeficientes $\beta_{padronizados}$ negativos indicando que o aumento da cobertura vegetal em razão da maior precipitação reduziu a média do IGSD em 4% e 2,6%, respectivamente. De acordo com o modelo logístico o aumento do NDVI pouco contribuiu na redução do risco desertificação, contudo, a evapotranspiração, albedo e temperatura além de aumentarem a média do IGSD em 5,2%, 3,6% e 5,1%, respectivamente, mostraram-se relevantes no aumento do risco a desertificação em 74,04% devido a temperatura e 99,99% em razão da evapotranspiração, sendo os mais importantes na predisposição a desertificação de acordo com o algoritmo Garson.

Para a etapa de validação os modelos apresentaram em ordem decrescente o seguinte desempenho: redes neurais>SVM>RLM>RL e na etapa de teste: RLM>redes neurais>SVM>RL (Tabela 9).

Tabela 9 - Métricas dos modelos nas fases de validação e teste em Miraíma

Modelo	**Período**	**Validação**			**Teste**		
		R^2	**R**	**RMSE**	**R^2**	**R**	**RMSE**
RLM	2005FC	0,7835	0,8851	0,0429	0,5886	0,7672	0,161
RL	2000FS	0,1824	-	-	0,0777	-	-
Redes Neurais	2005FC	0,9998	0,9999	0,0002	0,5344	0,7317	0,2098
SVM	2003FS	0,9934	0,9966	0,0872	0,4856	0,6968	0,1272

Fonte: Elaboração Própria.

O maior R^2 da rede neural e SVM quando comparado com o RLM indicou boa adequação destes na predição do risco a desertificação na etapa de validação, contudo na fase de teste o RMSE aumentou e o R^2 diminui, isso pode ter ocorrido em razão de problemas de

underfitting ou *overfitting* em consequência do tempo de treinamento e taxa de aprendizado destes modelos. De acordo com Li *et al*. (2022) redes neurais e SVM quando não bem treinadas reduzem a capacidade de generalização.

O RL apresentou menor R^2 Nagelkerke indicando pouca capacidade de explicar a variabilidade do status de desertificação em ambas as fases, de acordo com Clark e Hosking (1986) e Djeddaoui *et al*. (2017) modelos logísticos com R^2 Nagelkerke menores que 0,20 mostram-se inadequados.

Com exceção do SVM, o RLM e as redes neurais mostraram estimativas de IGSD abaixo dos intervalos de valores reais (subestimativas) e acima (superestimativas), sendo que a classe frágil foi a que apresentou mais estimativas fora de seu intervalo, com valores de IGSD preditos para a classe não afetado e potencial; em relação as superestimativas ambos os modelos classificaram as classes frágil e crítica como crítica e desertificada, respectivamente (Tabela 10).

Tabela 10 - Desempenho do RLM, Redes Neurais e SVM nas etapas de validação e teste em Miraíma

Modelo	**Subestimativa**		**Superstimativa**	
	IGSD Convencional	**IGSD Subestimado**	**IGSD Convencional**	**IGSD Superestimado**
RLM	1,2395 - 1,4259 (F, C)	1,0170 - 1,3557 (NA, P, F)	1,4501 - 1,6010 (C, D)	1,5262 - 1,8284 (D)
Redes Neurais	1,1699 - 1,2916 (NA, P, F)	1,1151 - 1,2079 (NA, P)	1,3686 - 1,6010 (F, C, D)	1,4771 - 2,0026 (C, D)
SVM	1,4342 - 1,5015 (C)	1,4342 - 1,5015 (C)	-	-

Fonte: Elaboração Própria; (-): não houve superestimativas do IGSD convencional.

Verifica-se que o RLM apresentou menor acurácia e kappa quando comparado com o SVM, contudo esse foi o mais assertivo em relação ao SVM, redes neurais e RL, apresentando menor MEO, MEC e maiores MTAC (Tabela 11).

Tabela 11 - Métricas dos modelos testados em Miraíma

Modelo	Miraíma				
	Acurácia	Kappa	MEO	MEC	MTAC
RLM	78,22	0,7345	38,42	25,65	64,65
RL	68,92	0,616	49,17	51,06	45,1
Redes Neurais	76,38	0,708	56,67	40,17	46,94
SVM	80,77	0,7566	58,75	31,96	59,22

Fonte: Elaboração Própria; MEO: média de erro de omissão (%); MEC: média de erro de comissão (%); MTAC: média de taxa de acerto de campo (%).

A rede neural e o SVM mostraram maiores MEO e MEC e menores MTAC isso pode ser justificado em razão das maiores confusões entre classes com respostas espectrais semelhantes, por exemplo, não afetado com potencial e crítico com frágil, estas classes são muito similares nas condições de vegetação e solo e diferenciá-las usando apenas o atributo espectral torna-se bastante difícil. O RL apresentou menor acurácia e kappa em razão da baixa capacidade de predição do modelo (R^2 Nagelkerke<0,20) resultando em menor poder de distinção entre as classes e maiores MEO e MEC e menores MTAC.

5.1.3 Mapas de IGSD em Miraíma (RLM, RL, Redes Neurais e SVM)

Os mapas de suscetibilidade a desertificação obtidos pelos modelos de regressão múltipla, logística, redes neurais e SVM estão contidos nas Figuras 7, 8, 9 e 10.

Figura 7 - Mapa de IGSD em Miraíma (regressão linear múltipla – 2005FC)

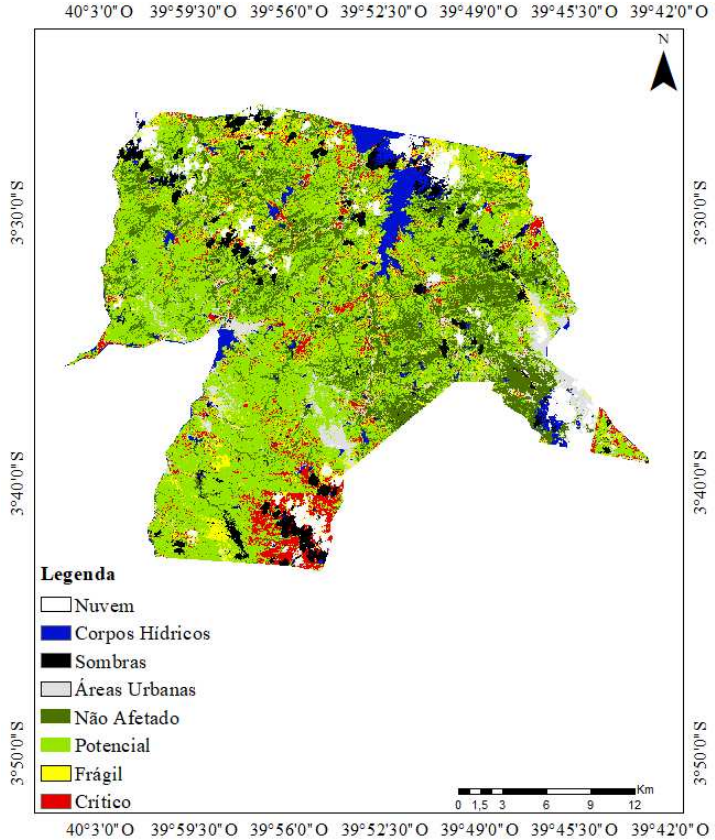

Figura 8 - Mapa de IGSD em Miraíma (regressão logística – 2000FS)

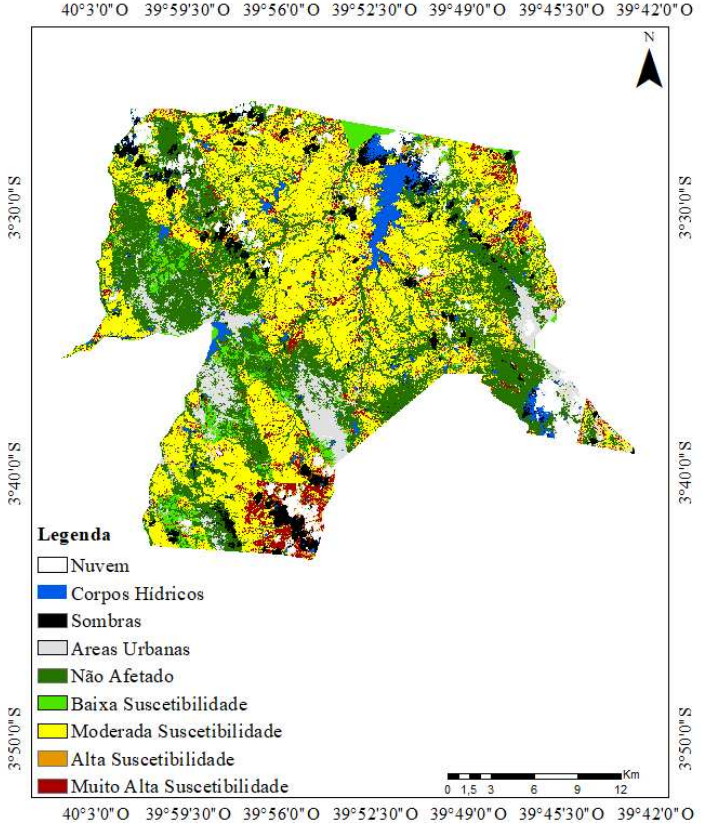

Fonte: Elaboração Própria; IGSD: Índice de Geométrico de Suscetibilidade a desertificação; RLM: Regressão Múltipla; RL: Regressão Logística.

Figura 9 - Mapa de IGSD em Miraíma (redes neurais – 2005FC)

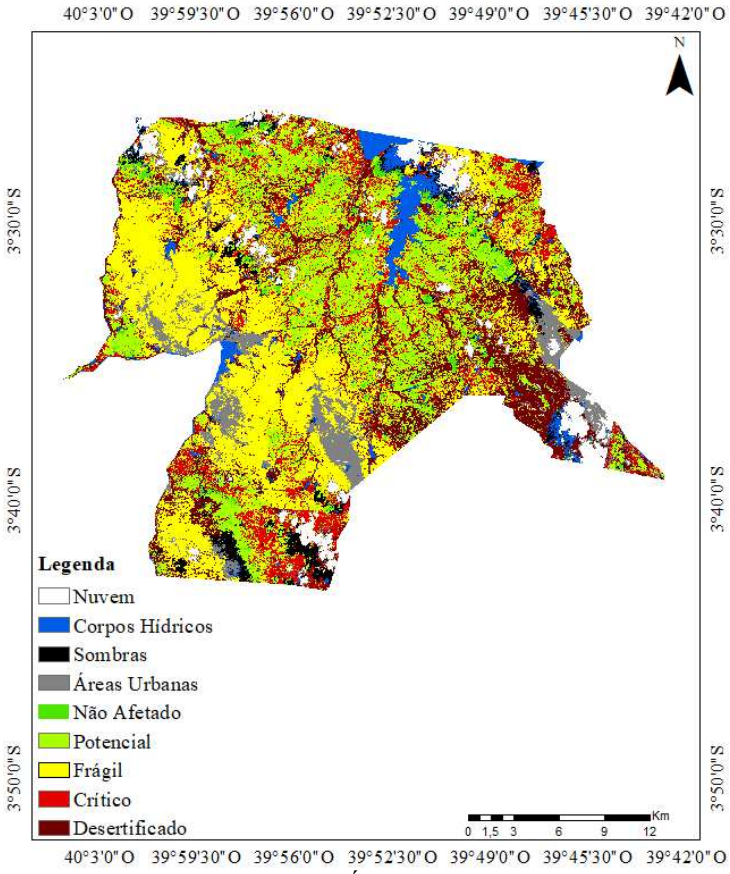

Figura 10 - Mapa de IGSD em Miraíma (*Support Vector Machine* – 2003FS)

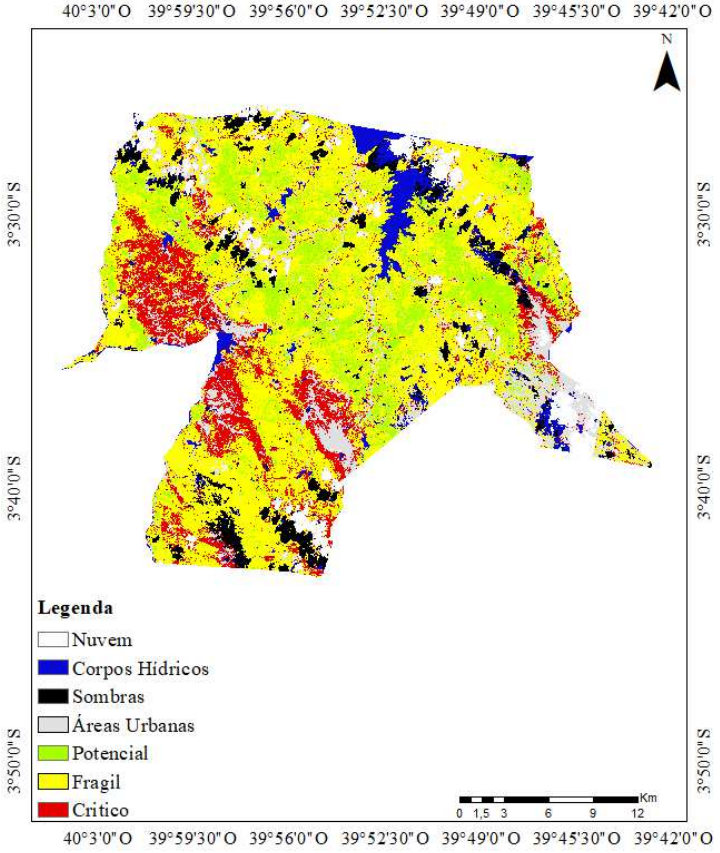

Fonte: Elaboração Própria; IGSD: Índice de Geométrico de Suscetibilidade a desertificação.

As classes não afetadas são áreas de uso sustentável em sistemas ambientais sertões Miraíma/Aracatiaçu com superfícies moderadamente dissecadas e precipitações entre 700 a 800 mm e vertente meridional da serra da Uruburetama com superfície dissecada e precipitações entre 890 a 900 mm, o uso sustentável e a conservação dos recursos naturais pelo não emprego de queimadas e desmatamento, associado com as precipitações em áreas de serras e a topografia contribuem para que os solos e a biodiversidade mantenham-se em bom estado de conservação (FUNCEME, 2015).

A vegetação densa com NDVI entre 0,4437 a 0,6593 atuou recobrindo e aportando matéria orgânica ao solo favorecendo a maior retenção de água e reduzindo o albedo, temperatura e evapotranspiração, de acordo com o RLM o aumento do NDVI reduz em 4% a média do IGSD e acarreta na redução do albedo, temperatura e evapotranspiração contribuindo para diminuições na média do IGSD em 3,6%, 5,1% e 5,2%, respectivamente. A redução da temperatura e evapotranspiração diminuíram os riscos a desertificação em 74% a 99,99%, respectivamente (DJEDDAOUI *et al*., 2017; JIANG *et al*., 2019; TOMASSELA *et al*., 2018; FUNCEME, 2015; SOUZA *et al*., 2020).

As áreas potenciais e de baixa suscetibilidade a desertificação localizam-se em zonas de recuperação ambiental com tendências progressivas em sistemas ambientais sertões Miraíma/Aracatiaçu e vertente setentrional da serra da Uruburetama, com alteração da cobertura vegetal original destas áreas e de zonas ripárias em razão de atividades de extrativismo, agricultura e pecuária extensiva. Em áreas consideradas com potencial suscetibilidade a desertificação pelo modelo RLM, Redes Neurais e SVM verificaram-se aumentos entre 40% a 67,6% na ocupação por pastagens sendo que 15% destas estão em estado de degradação (FUNCEME, 2015; SOUZA *et al*., 2020).

As correlações entre NDVI e Albedo (-0,9166) em áreas potenciais mostram que solos bem vegetados absorvem e irradiam menos calor para a atmosfera reduzindo o albedo e afetando o balanço energético e a evapotranspiração, aumentando a umidade e a precipitação. A degradação de zonas ripárias leva a alterações do microclima local podendo reduzir a umidade e a precipitação, resultando em aumento do risco a desertificação (NORMAN *et al*., 2022).

As classes frágil, moderada suscetibilidade, crítico e alta suscetibilidade, foram identificadas por todos os modelos e a classe desertificada e muito alta suscetibilidade pelos modelos de RL e redes neurais. Caracterizaram-se por estarem inseridas em zonas de recuperação ambiental com dinâmica ecológica regressiva nas áreas de sertões Miraíma/Aracatiaçu e vertente setentrional da serra da Uruburetama, indicando solos e

biodiversidades fortemente degradados e com capacidade produtiva dos recursos naturais comprometida em razão de atividades de extrativismo, desmatamento, pastagens com degradação severa e erosão que levaram a degradação da caatinga e a solos empobrecidos e rasos com afloramentos de rochas na superfície (FUNCEME, 2015).

Para as classes frágil, crítico, desertificado, moderada, alta e muito alta suscetibilidade a desertificação, verificaram-se aumentos de mais de 80% nas áreas destinadas as pastagens sendo que as degradações chegaram a 10%, isso reduziu o NDVI para valores entre 0,2528 a 0,4719 indicando desde solo exposto até vegetação esparsa e aumentou o albedo do solo entre 0,1094 a 0,1786 e a temperatura de 28°C a 32°C. Correlações entre os índices de NDVI, Albedo, precipitação, evapotranspiração e temperatura mostram a influência destes no risco a desertificação (Tabela 12).

Tabela 12 - Correlações de índices em Miraíma

Índices	**Correlações**
NDVI x Albedo	-0,9166
Albedo x Temperatura	0,9949
Albedo x Precipitação	-0,7486
Evapotranspiração x Temperatura	0,9452
Temperatura x Precipitação	-0,7917

Fonte: Elaboração Própria.

A correlação positiva albedo e temperatura tem consequências na redução da precipitação, pois em áreas frágeis, críticas, desertificadas, moderada, alta e muito alta suscetibilidade a desertificação, o aumento de temperatura demanda maior evapotranspiração da vegetação favorecendo ao fluxo de calor sensível que reduz a umidade do solo e a precipitação, acentuando a deficiência hídrica e consequentemente limitando o crescimento vegetativo, agravando a suscetibilidade a desertificação (JIANG *et al*., 2017; HAN *et al*., 2021).

Paras as classes frágil, moderada suscetibilidade, crítico, alta e muito alta suscetibilidade a desertificação a remoção da vegetação original para ocupação de pastagens submetidas as práticas agropecuárias extensivas em solos com restrições de uso reduziram a média do NDVI em 49,19% em relação as áreas não afetadas; já o aumento da degradação de pastagens pelo sobre pastejo pode levar a compactação e erosão do solo, acarretando em perda de nutrientes e de matéria orgânica e menores retenções de água, contribuindo para o aumento do albedo e temperatura, cujas as médias aumentaram em 36,77% e 6,06% em relação as áreas não afetadas.

O modelo de RL mostrou que o aumento de 1 grau Celsius na temperatura aumenta o risco a desertificação em 73%, a temperatura mostrou-se como variável mais importante pelo algoritmo Garson apresentando correlações negativas com a precipitação e o índice de aridez e positiva com o albedo.

A redução da cobertura vegetal seguido do aumento do albedo, temperatura e evapotranspiração impactou no microclima local, pois, favoreceu ao maior fluxo de calor sensível resultando na redução da probabilidade de condensação do vapor de água e acarretando em reduções de 5,3% nas médias das precipitações das áreas desertificadas em relação as não afetadas. De acordo com Ning *et al*. (2021) e Zolotokrylin *et al*. (2020) mudanças no microclima contribuem para maior escassez hídrica e menor umidade do solo, menor cobertura vegetal, maior erosão, resultando em perda da capacidade agrícola e aumentando o risco a desertificação.

O modelo de redes neurais mostrou que faixas de temperaturas entre 18°C a 22°C reduziram o IGSD, em razão do favorecimento da germinação das plantas devido a maior disponibilidade de umidade no solo, redução da refletância do solo e aumento da atividade microbiana, entretanto temperaturas acima de 32°C aumentaram o IGSD sobretudo em razão de serem faixas de temperaturas associado a solos sem vegetação e albedo elevado favorecendo a menor água disponível ao solo (JOSEPH, *et al*., 2018; DING; XINGMING, 2021; TOMASSELA *et al*., 2018; SUN *et al*., 2019).

O modelo RLM apresentou o melhor desempenho nas etapas de validação, teste, acurácia e kappa indicando boa consistência e foi capaz de identificar as classes NA, P, F, e C com menores MEO, MEC e maiores MTAC mostrando-se adequado para estudos de suscetibilidade a desertificação (LI *et al*., 2022; SALUNKHE *et al*., 2018).

A classe não afetada foi confundida com a potencial; e a crítica com a frágil isso pode ter ocorrido em razão da mistura espectral dos pixels correspondentes a estas classes, pois verificam-se semelhanças do comportamento espectral entre a classe não afetada e potencial apresentando zoneamento ecológico econômico do tipo uso sustentável e com tendências progressivas, respectivamente, indicando que nestas classes a capacidade produtiva dos recursos naturais e da biodiversidade mostram-se em condições equilibradas (FUNCEME, 2015).

As classes crítica e frágil apresentam zoneamento ecológico econômico do tipo zonas de recuperação com tendências regressivas apresentando respostas espectrais semelhantes que não foram distinguidas pelo modelo. Estudos feitos por Jawak *et al*. (2015) mostraram que considerar apenas a resposta espectral de alvos como amostras de treinamento

reduz o potencial do classificador na separação entre as classes.

O modelo RL mostrou menor desempenho nas fases de treinamento, validação, teste, acurácia, kappa, erros de omissão, comissão e taxas de acerto de campo. O baixo desempenho deve-se ao menor R^2 $_{Nagelkerke:}$ de 0,0777 na etapa de teste indicando baixa capacidade de predição da desertificação e ao número de amostras por classes preditas pelo modelo de teste com uma razão de 1:14, ou seja, para cada 1 pixel rotulado como desertificado 14 foram considerados como não afetados. De acordo com Djeddaoui *et al*. (2017) e Zhao *et al*. (2021) os desbalanceamentos entre o número de amostras das classes pode contribuir para modelos logísticos enviesados com baixa capacidade de distinção entre as classes e maior confusão.

Os modelos de Redes Neurais e SVM apresentaram melhores desempenhos nas etapas de treinamento/validação em relação aos modelos de RLM e RL, contudo o R^2 na etapa de teste foi menor, não impedindo que os mapas de IGSD apresentassem acurácias e kappas de boas consistências corroborando com os resultados apresentados por Feng *et al*. (2022) e LI *et al*. (2022).

O modelo de redes neurais confundiu as classes não afetadas e potenciais com corpos hídricos e sombras e a classe crítica com a frágil; já o SVM apresentou alta confusão das classes potenciais e críticas com a classe frágil, isso pode ser em razão da semelhança espectral destas classes e de problemas de *underfitting* ou *overfitting* verificado por maiores R^2 nas etapas de treinamento e menores na etapa de teste (FENG *et al*., 2022).

5.2 Canindé

5.2.1 RLM, RL, Redes Neurais e SVM

Para Canindé, os períodos de 1997FC,1998FC e 2006FC apresentaram os melhores modelos de regressão múltipla, logística, redes neurais e SVM. O NDVI, albedo, evapotranspiração e temperatura foram considerados significativos pelos modelos de RLM e RL (Tabela 13).

Tabela 13 - Índices e contribuições nas médias do IGSD e no risco a desertificação em Canindé

Local	RLM		RL	Redes Neurais
	Variáveis	**IGSD %**	**Risco (%)**	**(Garson Algoritmo)**
Canindé	NDVI	-3,41*	$4,82.10^{-5}$*	18
	TGSI	NS	NS	12
	Albedo	1,12*	99,99*	16
	Evapotranspiração	3,14*	99,77*	14
	Temperatura	3,76*	58,54*	38
	Índice de Aridez	-6,42*	NS	2
	Precipitação	NS	2,56*	8

Fonte: Elaboração Própria; * p – value<0,05; NS: não significativo – p – value>0,05; RLM – 1997FC: R^2: 0,827; RL - 1997FC: R^2 Nagelkerke: 0,848; Redes Neurais - 2006FC: R^2: 0,9474; sinal (-) indica redução em escala de percentual na média do IGSD.

O aumento da cobertura vegetal melhorou as condições de índice de aridez, contribuindo para a redução da média do IGSD em 3,41% e 6,42%, respectivamente, contudo o modelo de RL indicou menor efeito do NDVI na redução do risco a desertificação. Em conjunto, o albedo, evapotranspiração e temperatura aumentaram a média de IGSD em 8%, enquanto os riscos variaram entre 58,54% a 99,99%. De acordo com o algoritmo Garson a temperatura mostrou-se como a principal causa da desertificação, isso em razão da influência desta nos aspectos de clima, solo, vegetação e precipitação, sendo que o aumento da precipitação reduziu o risco a desertificação em mais de 2%.

O RLM apresentou maiores RMSE em ambas as etapas quando comparado ao SVM e redes neurais. Quanto a variabilidade explicada em ordem decrescente verifica-se o SVM>redes neuras>RLM>RL, apesar do RL apresentar R^2 Nagelkerke superior a 0,20 sendo adequado a predição da desertificação conforme Djeddaoui *et al*. (2017) e Clark e Hosking (1986) o desbalanceamento entre amostras desertificadas e não desertificadas pode justificar o menor poder preditivo deste em relação aos demais (Tabela 14).

Tabela 14 - Métricas dos modelos nas fases de validação e teste em Canindé

Modelo	**Período**	**Validação**			**Teste**		
		R^2	**R**	**RMSE**	**R^2**	**R**	**RMSE**
RLM	1997FC	0,7615	0,8726	0,0339	0,5132	0,7163	0,4634
RL	1997FC	0,2321	-	-	0,2765	-	-
Redes Neurais	2006FC	0,9474	0,9733	0,0254	0,5497	0,7414	0,1605
SVM	1998FC	0,9701	0,9849	0,0231	0,5353	0,7316	0,1136

Fonte: Elaboração Própria; RL: Regressão Logística: R^2 Nagelkerke.

O RLM e as redes neurais subestimaram os valores de IGSD convencional, enquanto o SVM mostrou-se mais preciso em razão de seu maior poder preditivo em explicar a variabilidade do IGSD (maior R^2) com menor RMSE (Tabela 15).

Tabela 15 - Desempenho do RLM, Redes Neurais e SVM nas etapas de validação e teste em Canindé

Modelo	Subestimativa		Superstimativa	
	IGSD Convencional	**IGSD Subestimado**	**IGSD Convencional**	**IGSD Subestimado**
RLM	1,1698 - 1,6010 (NA, P, F, C, D)	0,5555 - 1,4998 (NA, P, F, C)	-	-
Redes Neurais	1,1698 - 1,2915 (NA, P, F)	0,8607 - 1,1940 (NA, P)	-	-
SVM	-	-	-	-

Fonte: Elaboração Própria; (-): não houve estimativas acima ou abaixo do IGSD convencional.

O modelo de SVM apresentou maior acurácia e kappa, contudo identificou e classificou todas as comunidade de Canindé como de nível crítico, inviabilizando as avaliações com base em mapas de zoneamento ecológico econômico e a quantificação do MEO, MEC e MTAC, isso pode ter ocorrido em razão do sobreajuste do modelo de SVM em decorrência da amostragem empregada e tempo de treinamento do modelo, outra razão deve-se ao interpolador cujas estimativas predominaram dentro dos limites da classe crítica (1,38 a 1,53) afetando o desempenho do classificador de máxima verossimelhança (HANDELMAN; CHOR, 2017; ZHAO; *et al*., 2021) (Tabela 16).

Tabela 16 - Métricas dos modelos testados em Canindé

Modelo	Canindé				
	Acurácia	**Kappa**	**MEO**	**MEC**	**MTAC**
RLM	86,18	0,817	45,63	36,54	75,91
RL	72,11	0,6522	38,05	36,01	65,9
Redes Neurais	80,75	0,7489	73,06	39,28	72,12
SVM	91,96	0,8855	-	-	-

MEO: média de erro de omissão (%); MEC: média de erro de comissão (%); MTAC: média de taxa de acerto de campo; (-): dados indisponíveis.

O RLM mostrou-se mais adequado na identificação de áreas suscetíveis a desertificação, pois, o mapa obtido apresentou acurácia e kappa de excelente qualidade, com MEO e MEC menores e maiores MTAC. O RLM mostrou confusão entre as classes com

respostas espectrais semelhantes como não afetado com potencial; apesar dos menores MEO e MEC o RL mostrou-se com a menor acurácia e kappa indicando mapa de boa consitência com menores MTAC. O mapa de redes neurais mostrou – se de boa qualidade, entretanto maior MEO indica maior quantidade de pixels classificados fora de sua classe de referência.

5.2.2 Mapas de IGSD para Canindé (RLM, RL, Redes Neurais e SVM)

Os mapas de IGSD para Canindé obtido pelos modelos de RLM, RL, Redes Neurais e SVM estão contidos nas Figuras 11, 12, 13 e 14.

Figura 11 - Mapa de IGSD em Canindé (regressão linear múltipla – 1997FC)

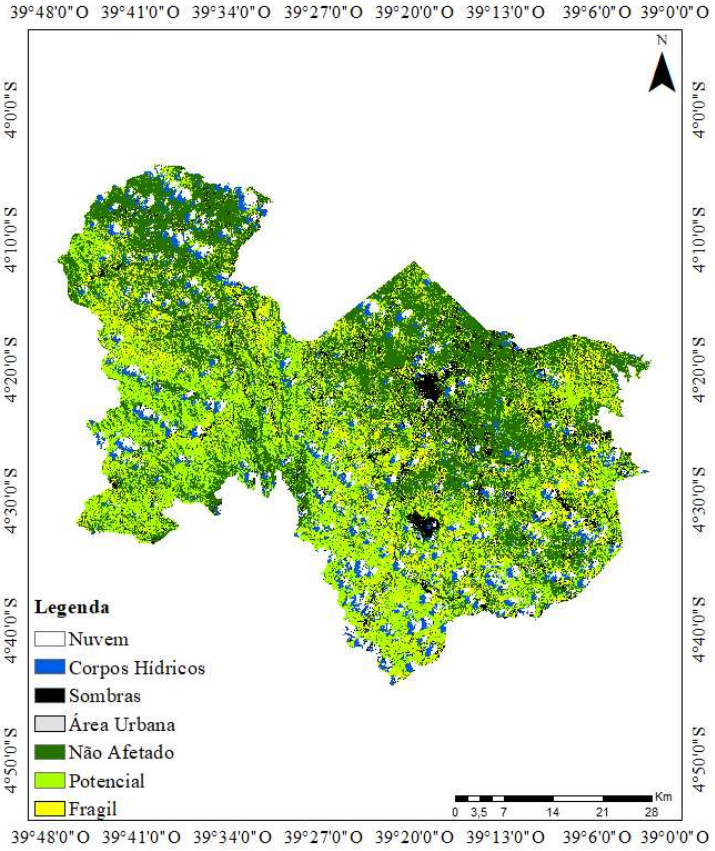

Figura 12 - Mapa de IGSD em Canindé (regressão logística – 1997FC)

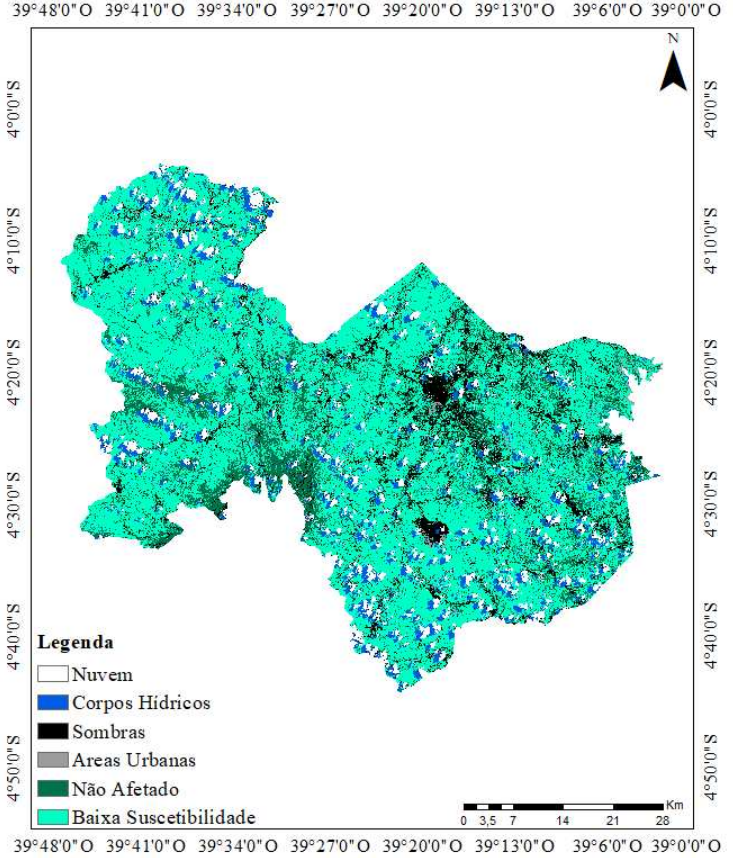

Fonte: Elaboração Própria; IGSD: Índice de Geométrico de Suscetibilidade a desertificação.

Figura 13 - Mapa de IGSD em Canindé (redes neurais – 2006FC)

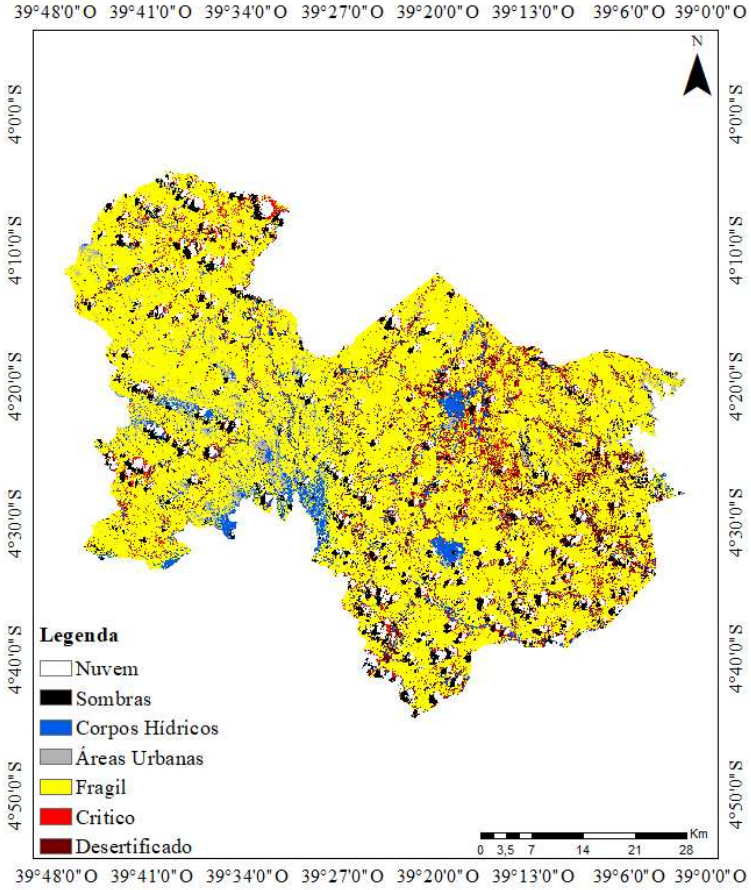

Figura 14 - Mapa de IGSD em Canindé (Support Vector Machine – 1998FC)

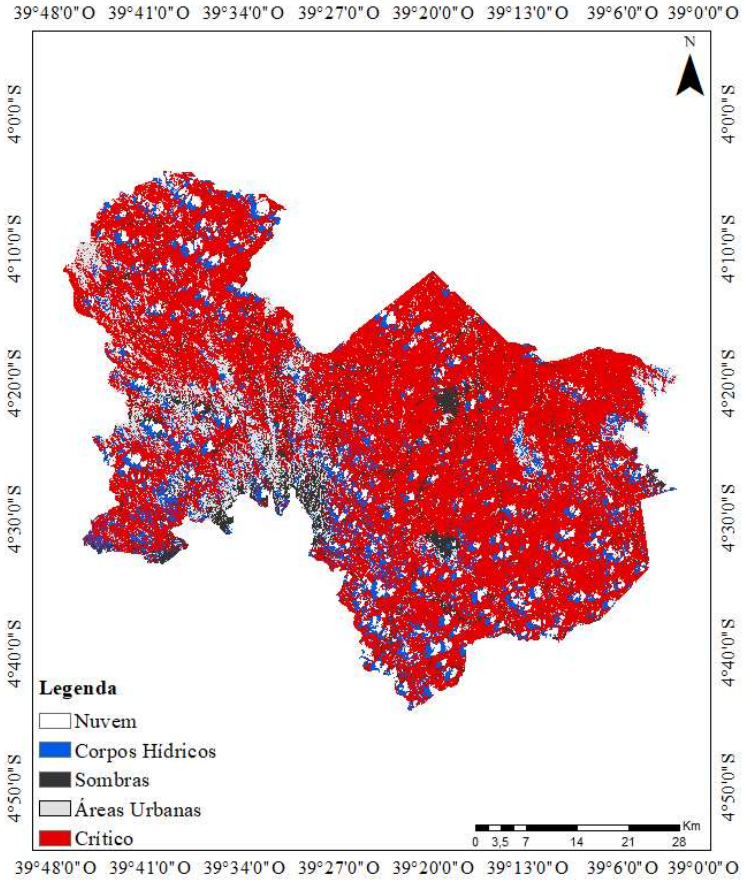

Fonte: Elaboração Própria; IGSD: Índice de Geométrico de Suscetibilidade a desertificação; SVM: *Support Vector Machine*.

As áreas não afetadas estão inseridas em zonas de uso sustentável nos domínios geomorfológicos dos sertões de Canindé constituído por superfícies moderadamente dissecadas com precipitações em 600 mm; e de Serras do Machado e de baixa vertente ocidental da Serra de Baturité com superfícies dissecadas com precipitações entre 580 a 740 mm, apresentam solos e biodiversidades conservados, com uso e ocupação baseado em práticas agropecuárias de cunho familiar. O uso sustentável das áreas de serras e de sertões, as precipitações e declividades nos domínios de serras diminuem a intervenção antrópica e contribuem para que os solos e a biodiversidade se mantenham em estado de equilíbrio com diferentes níveis de vegetação desde rala a densa o que favorece ao microclima favorável a não desertificação (FUNCEME, 2015; SOUZA *et al*., 2020).

A classe potencial e de baixa suscetibilidade a desertificação correspondem a zonas de recuperação ambiental em dinâmica progressiva nos domínios de sertões de Canindé e das baixas vertentes das serras do Machado e de Baturité apresentam solos parcialmente conservados, com caatinga e mata ciliar degradada pela alteração da vegetação original em razão da ocupação de agricultura de subsistência e pecuária extensiva, entre 2000 a 2018 as áreas ocupadas por pastagens aumentaram em 9,7% em territórios potencialmente suscetíveis a desertificação (FUNCEME, 2015; SOUZA *et al*., 2020).

As classes frágil, crítico e desertificado estão localizadas em zonas de recuperação ambiental com dinâmicas regressivas em razão de práticas agropecúarias extensivas que degradaram a caatinga e a mata ciliar para implantação de áreas de pastagens comprometendo os solos e biodiversidade, as áreas ocupadas por pastagens aumentaram em 11,3%, 50% e 70%, para as classes fragil, crítico e desertificado, respectivamente, sendo que 3,7% e 27,8% tornaram-se pastagens degradadas em áreas frágeis e desertificadas, respectivamente (SOUZA *et al*., 2020).

Os modelos de RLM mostraram que o aumento do NDVI e Índice de Aridez reduziram as médias do IGSD em 3,4% e 6,4%, respectivamente, em contrapartida o aumento do albedo, temperatura e evapotranspiração aumentaram a média do IGSD em 1,1%, 3,7% e 3,1%, respectivamente, o RL mostrou que o aumento do albedo, temperatura e evapotranspiração aumentaram os riscos a desertificação em 99,99%, 58,54% e 99,77%, respectivamente; as redes neurais mostraram que a temperatura, NDVI, albedo e evapotranspiração tem maiores importâncias na suscetibilidade a desertificação.

Alterações na cobertura vegetal afeta diretamente as condições de balanço de energia devido as correlações desta com o albedo e temperatura. Para as áreas não afetadas as práticas agropecuárias conduzidas de forma sustentável e os brejos de umidade das regiões

serranas aumentaram o NDVI reduzindo o albedo e a temperatura (Tabela 17).

Tabela 17 - Correlações de índices em Canindé

Índices	Correlações
NDVI x Albedo	-0,7820
NDVI x Temperatura	-0,6842
Temperatura x Albedo	0,6126

Fonte: Elaboração Própria.

De acordo com Li *et al*. (2022) e Zhang *et al*. (2022) a cobertura vegetal exerce influência nas condições climáticas de áreas de semiárido, pois, a adição de matéria orgânica ao solo melhora a sua agregação e aumenta a retenção de água, reduzindo os riscos a erosão, promovendo maior absorção da radiação solar e reduzindo a perda de umidade do solo mantendo as amplitudes de temperatura mais estáveis favorecendo ao maior fluxo de calor latente aumentando a probabiliade a precipitações e reduzindo o risco a desertificação.

De acordo com Norman *et al*. (2022) a implantação de pastagens para pastejo extensivo em solos com restrições de uso de planícies fluviais e inundação sazonal, contituiem risco potencial e de baixa suscetibilidade a desertificação, pois, a compactação e erosão acarreta na remoção de nutrientes e matéria orgânica do solo afetando a retenção de umidade e na reflectância do solo que altera o balanço de energia entre o solo e a atmosfera, modificando o microclima local e aumentando a suscetibiliadde a desertificação.

Nas áreas frágeis, críticas e desertificadas verificaram-se maiores ocupações de pastagens degradadas pelo pastoreio extensivo com altas de lotação em solos com restrições de uso, permitindo inferir a existência de solos compactados oferecendo maior resistência a penetração das raízes, acarretando em menor condição de suporte a vegetação e na redução da média do NDVI em 32,32% em relação as áreas não afetadas.

Depreende-se que a diminuição da cobertura vegetal aumenta a exposição do solo a erosão e a perda de matéria orgânica e nutriente, aumentando a média de albedo em 32,48% e de temperatura em 3,8%, em relação a áreas não afetadas. De acordo com Ning *et al*. (2021) e Zolotokrylin *et al*. (2022) mudanças na vegetação em razão de atividades antrópicas resultam em alterações no balanço de energia entre o solo e atmosfera modificando o microclima pela maior conversão da radiação solar em fluxo de calor sensível o que aumenta as amplitudes de temperaturas e favorecem as trocas térmicas secas diminuindo a probabilidade de condensação e precipitação, aumentando o risco a desertificação.

O modelo RLM apresentou melhor desempenho nas etapas de treinamento, validação, teste, acurácia, kappa, menores erros de omissão, comissão e maiores taxas de acerto indicando seu potencial para suscetibilidade a desertificação, corroborando com os estudos de Karavitis *et al*. (2020) e Salunkhe *et al*. (2018) que provou a eficiência destes no monitoramento de áreas com riscos a desertificação.

O modelo RL apresentou menor desempenho verificado pelo menor número de classes identificadas e menores taxas de acerto em razão de maiores erros de omissão e comissão, o desbalanceamento das amostras entre as classes desertificadas e não afetadas pode levar a resultados enviesados do modelo (ZHAO *et al*., 2021).

O modelo de redes neurais apresentou desempenhos satisfatórios nas etapas de treinamento/validação, teste, acurácia e kappa, contudo verificaram-se maiores erros de omissão, comissão e menores taxas de acerto de campo; o SVM identificou apenas a classe crítica inviabilizando a obtenção de métricas para avaliar o desempenho do modelo. O melhor desempenho destes modelos pode ser alcançado com maior tempo de treinamento dos dados para obtenção de redes neurais e SVM ótimas com maior capacidade de aprendizado e generalização e menos suscetíveis ao *underfitting* e *overfitting*, ambos os modelos apresentaram maiores R^2 nas etapas de treinamento/validação e menores na etapa de teste sendo indicativo de problemas de *underfitting* ou *overfitting* (FENG *et al*., 2022; LI *et al*., 2022).

O modelo de RLM confundiu a classe potencial e frágil com a classe não afetada, o logístico a classe BS com NA e as redes neurais as classes frágil, crítico e desertificado, isso pode ter ocorrido em razão de semelhanças das respostas espectrais destas classes, acarretando em maiores confusões entre elas. Estudos de Jawak *et al*. (2015) sugerem que para evitar este problema é necessário caracterizar a classe além da dimensão espectral com atributos relacionados a forma, textura, cor e continuidade espacial.

5.3 Irauçuba

5.3.1 RLM, RL, Redes Neurais e SVM

O NDVI e o índice de aridez reduziram as médias do IGSD e os riscos a desertificação, o algoritmo Garson mostrou que a vegetação foi o fator mais importante na redução da desertificação, pois, a maior média do NDVI no período de 1999FC contribuiu para que a média do IGSD se reduzisse em 7,2% (Tabela 18).

Tabela 18 - Índices e contribuições nas médias do IGSD e no risco a desertificação em Irauçuba

Local	RLM		RL	Redes Neurais
	Variáveis	**IGSD %**	**Risco (%)**	**(Garson Algoritmo)**
Irauçuba	NDVI	-3,72*	$8{,}43.10^{-5}$*	38
	TGSI	NS	NS	10
	Albedo	NS	100*	10
	Evapotranspiração	3,88*	99,99*	15
	Temperatura	3,77*	70,26*	29
	Índice de Aridez	-3,57*	$2{,}57.10^{-5}$*	1
	Precipitação	NS	NS	3

Fonte: Elaboração Própria; * p – value<0,05; NS: não significativo – p – value>0,05; RLM – 1997FC: R^2: 0,801; RL - 2005FC: R^2 Nagelkerke: 0,7200; Redes Neurais - 1999FC: R^2: 0,9601; sinal (-) indica redução em escala de percentual na média do IGSD.

A evapotranspiração e a temperatura aumentaram a média do IGSD em mais de 7%, enquanto os riscos a desertificação variaram entre 70,26% a 100%. De acordo com o algoritmo Garson, a evapotranspiração, temperatura e albedo representam 54% na ocorrência da desertificação, com destaque para a temperatura que é responsável pela regulagem de umidade do solo, fluxo de energia entre o solo e a atmosfera e precipitação. O período de 2005FC apresentou as maiores médias de temperatura e evapotranspiração o que aumentou a demanda evaporativa do solo e das plantas favorecendo a menor disponibilidade de água no solo, aumentando o albedo e fluxo de calor sensível que reduz a probabilidade de precipitação, agravando o risco a desertificação.

O SVM e a rede neural mostraram melhores desempenhos nas etapas de validação e teste, ambos apresentaram R^2 entre 0,6544 a 0,9832 com menores RMSE. O RLM explicou 66,81% e 53,28% nas fases de validação e teste, respectivamente, com maiores erros de predição (RMSE) em comparação as redes neurais e SVM. O RL apresentou pseudo R^2 indicativo de bom ajustamento na validação, em contrapartida com os dados de teste o modelo mostrou-se limitado (DJEDDAOUI *et al*., 2017). De acordo com Zhao *et al*. (2020) o tamanho amostral pode ter afetado o estimador de máxima verossimilhança do RL, pois, o maior R^2 na validação se deu com amostras cuja relação entre pixels não desertificados e desertificados era de 1:1, enquanto na etapa de teste era de 1:2,47 o que resultou em predições enviesadas (Tabela 19).

Tabela 19 - Métricas dos modelos nas fases de validação e teste em Irauçuba

Modelo	Período	Validação			Teste		
		R^2	R	RMSE	R^2	R	RMSE
RLM	1997FC	0,6681	0,8173	0,032	0,5328	0,7299	0,1136
RL	2005FC	0,4638	-	-	0,1433	-	-
Redes Neurais	1999FC	0,9601	0,9798	0,025	0,6832	0,8265	0,1522
SVM	2012FS	0,9832	0,9915	0,0121	0,6544	0,8089	0,0880

Fonte: Elaboração Própria; RL: Regressão Logística - R^2 Nagelkerke.

O RLM e as redes neurais mostraram estimativas de IGSD acima e abaixo dos valores reais, verifica-se que a classe desertificada foi subestimada pelo RLM com predições associadas a classe crítica, enquanto as classes não afetado e potencial foram classificadas como frágil e crítico. O modelo de redes neurais apresentou estimativas que omitiram a classe crítica, sendo subestimada para as classes não afetado, potencial e frágil e superestimada para a classe desertificado. O SVM não subestimou o IGSD, porém, a classe frágil apresentou estimativas associado a classe crítica e desertificada, a melhor predição do IGSD pelo SVM deve-se ao menor RMSE na etapa de teste e validação quando comparado ao RLM e redes neurais (Tabela 20).

Tabela 20 - Desempenho do RLM, Redes Neurais e SVM nas etapas de validação e teste em Irauçuba

Modelo	Subestimativa		Superstimativa	
	IGSD Convencional	IGSD Subestimado	IGSD Convencional	IGSD Superestimado
RLM	1,5110 - 1,6403 (C, D)	1,4831 - 1,5385 (C)	1,1699 - 1,3686 (NA, P, F)	1,2225 - 1,4018 (F, C)
Redes Neurais	1,1699 - 1,4260 (NA, P, F, C)	0,8896 - 1,3017 (NA, P, F)	1,5366 - 1,6403 (C, D)	1,6374 - 1,8709 (D)
SVM	-	-	1,3686 - 1,4501 (F, C)	1,4100 - 1,5427 (C, D)

Fonte: Elaboração Própria; (-): não houve subestimativas do IGSD convencional.

Com exceção do RL, todos os modelos apresentaram mapas cuja a acurácia e kappa mostraram boa qualidade (LI *et al*., 2022). Destaca-se o RLM com maior acurácia e kappa cuja o mapa obtido identificou as classes não afetado, potencial, frágil e critico com menores MEO, MEC e maiores MTAC. O RL, redes neurais e SVM apresentaram maiores MEO e MEC contribuindo para menores MTAC, isso se deve a dificuldade destes em distinguir classes com respostas espectrais semelhantes como potencial com não afetada e de baixa suscetibilidade,

bem como crítico com frágil, desertificado, alta suscetibilidade e muito alta suscetibilidade, para estas classes verificam-se condições de clima, solo e vegetação similares demandando o uso de outros atributos para melhor segregação destas (JAWAK *et al*., 2015). (Tabela 21).

Tabela 21 - Métricas dos modelos testados em Irauçuba

Modelo	**Irauçuba**				
	Acurácia	**Kappa**	**MEO**	**MEC**	**MTAC**
RLM	74,69	0,688	39,43	36,92	46,85
RL	68,84	0,5883	36,93	37,35	33,18
Redes Neurais	67,87	0,6047	51,47	49,11	39,86
SVM	68,56	0,6126	43,16	42,19	19,75

MEO: média de erro de omissão (%); MEC: média de erro de comissão (%); MTAC: média de taxa de acerto de campo (%).

Apesar dos modelos de Redes Neurais e SVM apresentarem os maiores R^2 na etapa de teste estes mostraram menores MTAC, especialmente o SVM, a razão para isso pode está associado a limitação destes na generalização do conhecimento adquirido sobre o conjunto de dados, mensurada por taxas de aprendizado durante a etapa de treinamento, permitindo identificar possíveis problemas de *overfitting* ou *underfitting,* autores como Feng *et al.* (2022) e *Li et al*. (2022*)* argumentam a importância de avaliar continuamente as taxas de aprendizado destes modelos durantes etapas de treinamento e validação afim de escolher o melhor modelo que garanta maior generalização do conhecimento.

O mapa obtido pelo RL indicou qualidade intermediária (kappa<0,6) isso pode está relacionado ao menor R^2 nagelkerke na fase de teste, pois, valores inferiores a 0,20 indicam baixo poder preditivo do modelo, destaca-se também o número de exemplos por classe na fase de teste cuja a relação entre pixels não desertificados e desertificados foi de 1:2,47 podendo afeta as predições do estimador de máxima verossimilhança (DJEDDAOUI *et al*., 2017; ZHAO *et al*., 2020).

5.3.2 Mapas de IGSD para Irauçuba (RLM, RL, Redes Neurais e SVM)

Os mapas de IGSD para Irauçuba obtido pelos modelos de RLM, RL, Redes Neurais e SVM estão contidos nas Figuras 15, 16, 17 e 18.

Figura 15 - Mapa de IGSD em Irauçuba (regressão linear múltipla – normalizado – 1997FC)

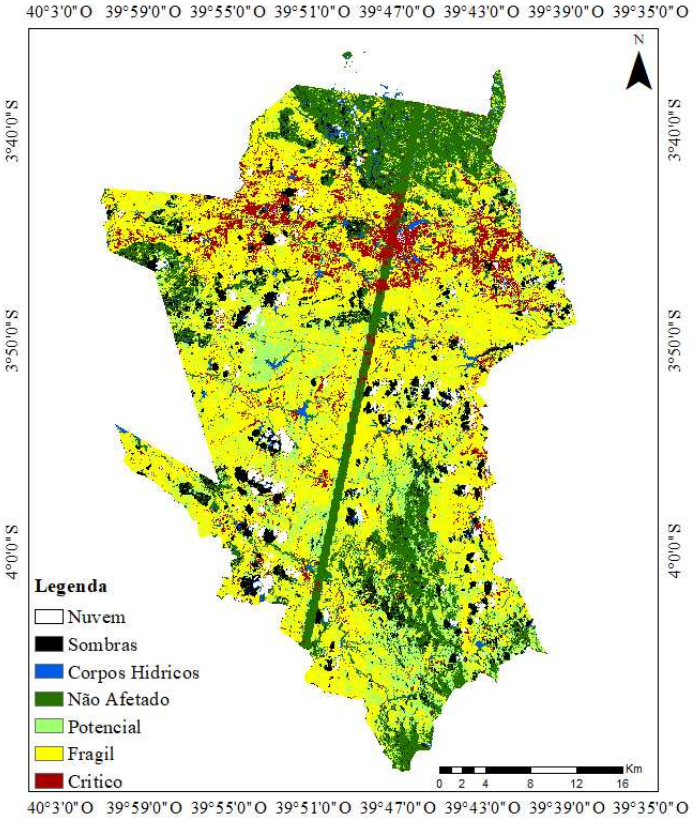

Figura 16 - Mapa de IGSD em Irauçuba (regressão logística – normalizado – 2005FC)

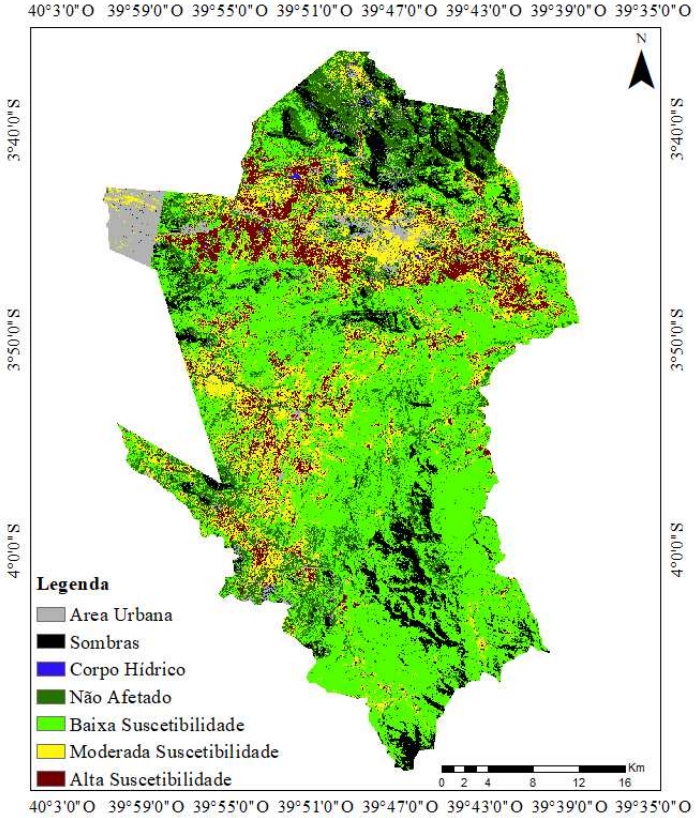

Fonte: Elaboração Própria; IGSD: Índice de Geométrico de Suscetibilidade a Desertificação.

Figura 17 - Mapa de IGSD em Irauçuba (redes neurais – normalizado – 1999FC)

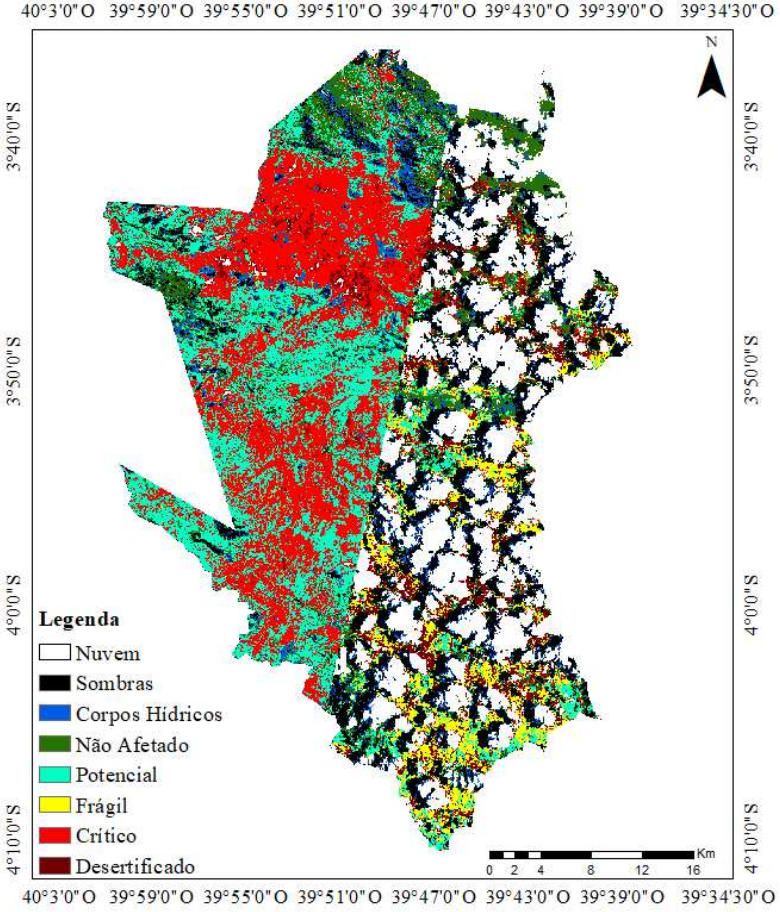

Figura 18 - Mapa de IGSD em Irauçuba (*Support Vector Machine* – normalizado - 2012FS)

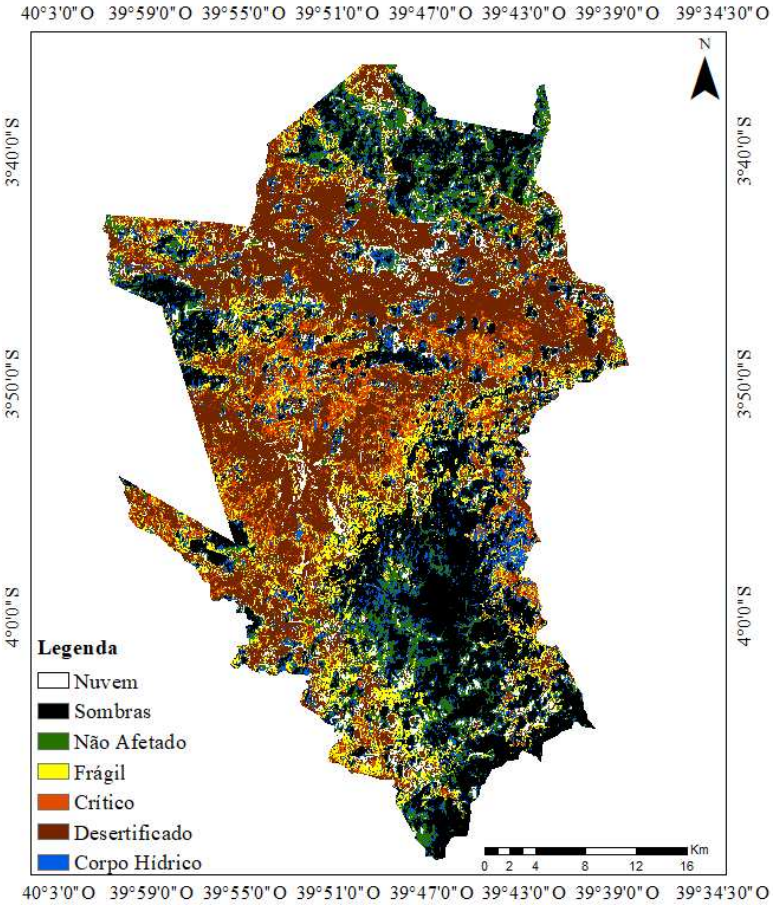

Fonte: Elaboração Própria; IGSD: Índice de Geométrico de Suscetibilidade a Desertificação.

As áreas não afetadas apresentaram-se localizadas em zonas de uso sustentável dos domínios dos sertões com superfície pedi planada a moderadamente dissecada e precipitações entre 600 a 890 mm; e da vertente meridional da serra da Uruburetama apresentando superfícies mais dissecadas com precipitações entre 890 a 900 mm, apresentam solos e biodiversidades conservados, com exploração agropecuária sustentável. O uso sustentável em áreas de serras e de sertões, as precipitações e declividades nos domínios de serras contribuíram para que os solos e a biodiversidade se mantivessem em estado conservado com diferentes níveis de vegetação desde rala a densa permitindo condições favoráveis a não desertificação (FUNCEME, 2015; SOUZA *et al*., 2020).

As áreas potenciais e de baixa suscetibilidade a desertificação estão localizadas em zonas de recuperação ambiental com dinâmica progressiva em áreas de sertões e de serras, apresentam solos parcialmente conservados, com caatinga e mata ciliar degradada pela alteração da vegetação original em razão da ocupação de agricultura de subsistência e pecuária extensiva. Entre 2000 a 2018 as áreas ocupadas por pastagens aumentaram em 43,44% e a degradação destas em 20,65% (FUNCEME, 2015; SOUZA *et al*., 2020).

As áreas frágeis e de moderada suscetibilidade a desertificação estão localizadas em zonas de recuperação ambiental com dinâmicas regressivas em áreas de sertões e de serras, caracterizam-se por apresentarem solos e biodiversidades comprometidos apresentando caatinga e a mata ciliar degradada em razão do desmatamento para ocupação de pastagens extensivas e a degradação destas, as áreas ocupadas por pastagens e de pastagens degradadas entre 2000 a 2018 aumentaram em 49,74% e 50,7%, respectivamente (FUNCEME, 2015; SOUZA *et al*.,2020).

As áreas críticas e desertificadas estão localizadas desde zonas de recuperação ambiental com dinâmicas regressivas a fortemente degradadas, respectivamente, em domínios de sertões e de serras, apresentam solos e biodiversidades comprometidos em áreas críticas; e irreversivelmente comprometidos em áreas desertificadas (FUNCEME, 2015). Na classe crítica, entre 2000 a 2018, as áreas ocupadas por pastagens e pastagens degradadas aumentaram em 42,36% e 44,50%, respectivamente, em áreas desertificadas, no mesmo período, os aumentos foram de 38,39% e 49,34%, respectivamente (SOUZA *et al*., 2020).

O modelo de RLM mostrou que o aumento do NDVI e Índice de Aridez reduziram as médias do IGSD em 3,7% e 3,5%, respectivamente, em contrapartida o aumento da temperatura e evapotranspiração aumentaram a média do IGSD em 3,7%, e 3,8%, respectivamente. O modelo RL mostrou que o aumento do albedo, temperatura e evapotranspiração aumentaram os riscos a desertificação em 100%, 70,26% e 99,99%,

respectivamente.

A pressão antrópica pelo aumento do desmatamento para ocupação de áreas de pastagens, agropecuária extensiva em solos com limitações de uso, pastagens degradadas e ausência de técnicas de manejo e conservação do solo e da biodiversidade acarretaram alterações na cobertura vegetal afetando as condições de balanço de energia devido as correlações dos índices de NDVI, albedo, temperatura e precipitação (Tabela 22).

Tabela 22 - Correlações de índices em Irauçuba

Índices	**Correlações**
NDVI x Albedo	-0,9961
Albedo x Temperatura	0,2638
Temperatura x Precipitação	-0,9483

Fonte: Elaboração Própria.

Para as áreas não afetadas o uso sustentável dos solos e da biodiversidade, bem como as maiores precipitações em regiões serranas e a topografia que dificulta a presença antrópica contribuíram para manutenção de boa cobertura vegetal com NDVI entre 0,3252 a 0,6292, reduzindo o albedo e a temperatura, de acordo com Li *et al*. (2022) a cobertura vegetal tem maior absorção da radiação solar e reduz a perda de umidade do solo, mantendo as temperatura mais estáveis, favorecendo ao maior fluxo de calor latente e maior probabilidade a ocorrencias de precipitações, reduzindo o risco a desertificação.

O desmatamento para implantação de pastagens destinadas ao pastejo extensivo em solos com restrições de uso das áreas de planícies fluviais e inundação sazonal, contituem risco potencial e de baixa suscetibilidade a desertificação, de acordo com Norman *et al*. (2022) a alteração da cobertura vegetal primária seguido do pisoteio excessivo pode levar a compactação do solo e erosão, acarretando na remoção de nutrientes e matéria orgânica do solo e afetando a retenção de umidade e a reflectância do solo que afeta o balanço de energia entre o solo e a atmosfera, alterando o microclima local e aumentando a suscetibiliadde a desertificação.

As áreas frágeis, moderada suscetibilidade, críticas e desertificadas tiveram maiores ocupações de áreas de pastagens e pastagens degradadas, reduzindo em 55% a média do NDVI em relação ao NDVI de áreas não afetadas. A ocupação pelo pastoreio extensivo com altas de lotação em solos com restrições de uso, podem levar a compactação do solo e aumento da resistência a penetração das raízes, resultando em menor condição de suporte a vegetação e aumento da erosão, levando a perda de matéria orgânica e nutrientes, reduzindo a retenção de

umidade. Diante desse contexto, a média do albedo aumentou em 35,29% e de temperatura em 17,88%, quando comparado com áreas não afetadas.

De acordo com Ning *et al*. (2021) e Zolotokrylin *et al*. (2020) o aumento do albedo e temperatura afetaram o microclima pela maior evapotranspiração da vegetação esparsa e conversão da radiação solar em fluxo de calor sensível favorecendo as trocas térmicas secas diminuindo as probabilidades de precipitações que mostraram reduções de 8,8% nas áreas desertificadas em relação as não afetadas contribuindo para o aumento do risco a desertificação.

O modelo RLM apresentou bom desempenho nas etapas de treinamento, validação e teste, resultando na obtenção de mapa de IGSD com acurácia e kappa de boa qualidade que foi capaz de identificar as classes não afetado, potencial e frágil e crítico com menores MEO, MEC e maiores MTAC. Estes resultados corroboram com os modelos de regressão múltipla encontrados por Salunkhe *et al*. (2018) e Li *et al*. (2022), que provaram o potencial destes modelos no reconhecimento de áreas desertificadas.

Os modelos de redes neurais e SVM apresentram maiores R^2 nas etapas de treinamento/validação e teste resultando em mapas de IGSD com acurácias e kappas de boa consistência, porém com maiores erros de omissão e menores TAC. De acordo com Feng *et al*. (2022) e Li *et al*. (2022) estes modelos podem ser otimizados por meio do aumento do tempo de treinamento e avaliações de taxas de aprendizados para se obter boa capacidade de aprendizado e generalização e evitar problemas de *overfitting* ou *underfitting*.

O modelo de RL mostrou bom desempenho na etapa de treinamento e validação, porém baixo na etapa de teste com $R^2_{Nagelkerke}$ inferior a 0,20, resultando em mapa com acurácia e kappa de boa consistência. Este modelo foi mais assertivo apresentando maiores TAC em relação ao RLM, Redes Neurais e SVM, de acordo com Zhao *et al*. (2021) o maior R^2 Nagelkerke na etapa de treinamento e validação deve-se as amostras de pixels desertificados e não desertificados que teve a proporção de 1:2,4, ou seja, para cada um 1 pixel desertificado havia 2,4 pixels não desertificados, isso favoreceu ao melhor desempenho do classificador.

O modelo RLM mostrou confusão entre a classe frágil e potencial; o RL entre BS e NA, redes neurais e SVM entre NA e potencial; desertificado e crítico, respectivamente. Isso ocorreu em razão da similaridade espectral entre estas classes. De acordo com Jawak *et al*. (2015) o uso do atributo espectral do pixel como forma de identificação e classificação da suscetibilidade a desertificação sem levar em consideração atributos do objeto classe relacionados a forma, cor, continuidade espacial e textura contribuiram para maiores confusões destas classes afetando os desempenhos dos modelos.

5.4 Santa Quitéria

5.4.1 RLM, RL, Redes Neurais e SVM em Santa Quitéria

Para o RLM o NDVI e o índice de aridez reduziram a média do IGSD em 5,56 % e 2,85%, respectivamente, no período de 2018FC foram registrados maiores médias de precipitações que aumentaram a cobertura vegetal e o índice de aridez contribuindo para redução do risco a desertificação conforme mostra o modelo logístico (Tabela 23).

Tabela 23 - Índices e suas contribuições nas médias do IGSD e no risco a desertificação em Santa Quitéria

Local	RLM		RL	Redes Neurais
	Variáveis	**IGSD %**	**Risco (%)**	**(Garson Algoritmo)**
Santa Quitéria	NDVI	-5,56*	$2{,}45.10^{-5}$*	22
	TGSI	2,32*	99,99*	2
	Albedo	NS	NS	38
	Evapotranspiração	1,93*	99,78*	15
	Temperatura	2,09*	61,49*	2
	Índice de Aridez	-2,85*	NS	8
	Precipitação	NS	NS	6

Fonte: Elaboração Própria; * p – value<0,05; NS: não significativo – p – value>0,05; RLM – 2018FC: R^2: 0,6500; RL - 2018FC: R^2 Nagelkerke: 0,841; Redes Neurais - 2011FS: R^2: 0,9298; sinal (-) indica redução em escala de percentual na média do IGSD.

O TGSI, evapotranspiração e temperatura foram responsáveis pelo aumento da média do IGSD em 2,32%, 1,93% e 2%, respectivamente. Os riscos a desertificação foram agravados pelo aumento destes índices, de acordo com o modelo logístico o aumento do TGSI e da evapotranspiração aumentaram os riscos a 100%, o aumento de temperatura elevou o risco a 61,49%. As maiores variações de temperaturas levaram ao aumento do albedo e da evapotranspiração reduzindo a umidade disponível para as plantas e para a formação de precipitações, agravando o risco a desertificação. O albedo mostrou-se como a variável mais importante na predição da desertificação, isso em razão da forte presença de NEOSSOLOS LITÓLICOS com textura arenosa a média com teores de areia superiores a 70%, cuja constituição mineralógica é o quartzo caracterizado pela maior reflectância e menor retenção de água.

Os modelos de redes neurais e SVM apresentaram maiores R^2 nas fases de validação e teste, porém com maiores RMSE. O RLM apresentou menor R^2 indicando menor poder de explicação da variabilidade do IGSD, contudo apresentou menores erros de predições

(RMSE); para o RL o menor R^2 na fase de teste indica baixa capacidade preditiva do modelo (Tabela 24).

Tabela 24 - Métricas dos modelos nas fases de validação e teste em Santa Quitéria

Modelo	Período	Validação			Teste		
		R^2	R	RMSE	R^2	R	RMSE
RLM	2018FC	0,65	0,806	0,0109	0,6369	0,798	0,041
RL	2018FC	0,841	-	-	0,1206	-	-
Redes Neurais	2011FS	0,9298	0,9642	0,0292	0,6534	0,8083	0,0882
SVM	2016FC	0,9348	0,9668	0,028	0,6165	0,7851	0,0792

Fonte: Elaboração Própria; RL: Regressão Logística - R^2 Nagelkerke.

Em relação as predições, o RLM superestimou a classe não afetado com resultados associados a classe potencial e frágil e o SVM subestimou a classe crítica cujas as predições foram compatíveis com a classe frágil. A rede neural apresentou estimativas mais condizentes com os valores originais, isso pode está relacionado ao maior poder explicativo na fase de teste (Tabela 25).

Tabela 25 - Desempenho do RLM, Redes Neurais e SVM nas etapas de validação e teste em Santa Quitéria

Modelo	Subestimativa		Superstimativa	
	IGSD Convencional	IGSD Subestimado	IGSD Convencional	IGSD Superestimado
RLM	-	-	1,0596 - 1,3135 (NA, P, F)	1,1798 - 1,3366 (P, F)
Redes Neurais	-	-	-	-
SVM	1,3686 - 1,4260 (F, C)	1,3122 - 1,3909 (F)	-	-

Fonte: Elaboração Própria; (-): não houve superestimativas do IGSD convencional.

Exceto a rede neural, todos os modelos produziram mapas que apresentaram boa qualidade, sendo que o RLM apresentou menor RMSE nas fases de validação e teste mostrando predições mais condizentes com a realidade justificando menores MEO e MEC e consequentemente maiores MTAC. De modo geral as MTAC para todos os modelos foram inferiores a 60%, em razão das dificuldades destes em distinguir classes com respostas espectrais semelhantes mostrando maiores confusões verificado pelo MEO e MEC. Os modelos não paramétricos apresentaram menores desempenhos na MTAC o que permite questionar

sobre a capacidade destes em emular os dados, a literatura enaltece a importância de avaliar as taxas de aprendizados destes modelos nas etapas de treinamento e teste afim de garantir melhor aprendizado destes na modelagem do conjunto de dados (FENG *et al*., 2022; LI *et al*., 2022) (Tabela 26).

Tabela 26 - Métricas dos modelos testados em Santa Quitéria

Modelo	**Santa Quitéria**				
	Acurácia	**Kappa**	**MEO**	**MEC**	**MTAC**
RLM	80,73	0,757	42,68	49,72	54,41
RL	76,43	0,7106	47,16	54	56,77
Redes Neurais	64,64	0,5565	49,29	49,62	13,45
SVM	81,81	0,7682	42,75	45,45	35,66

MEO: média de erro de omissão (%); MEC: média de erro de comissão (%); MTAC: média de taxa de acerto de campo (%).

5.4.2 Mapas de IGSD para Santa Quitéria (RLM, RL, Redes Neurais e SVM)

Os mapas de IGSD para Santa Quitéria obtido pelos modelos de RLM, RL, Redes Neurais e SVM estão contidos nas Figuras 19, 20, 21 e 22.

Figura 19 - Mapa de IGSD em Santa Quitéria (regressão linear múltipla – normalizado - 2018FC)

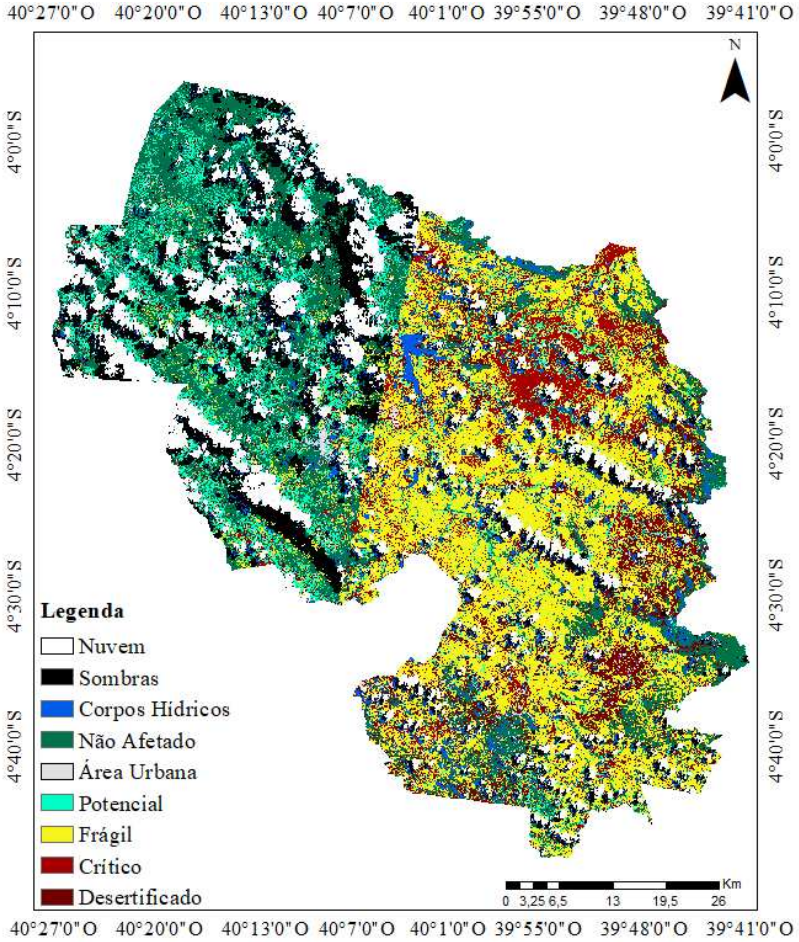

Figura 20 - Mapa de IGSD em Santa Quitéria (regressão logística – normalizado – 2018FC)

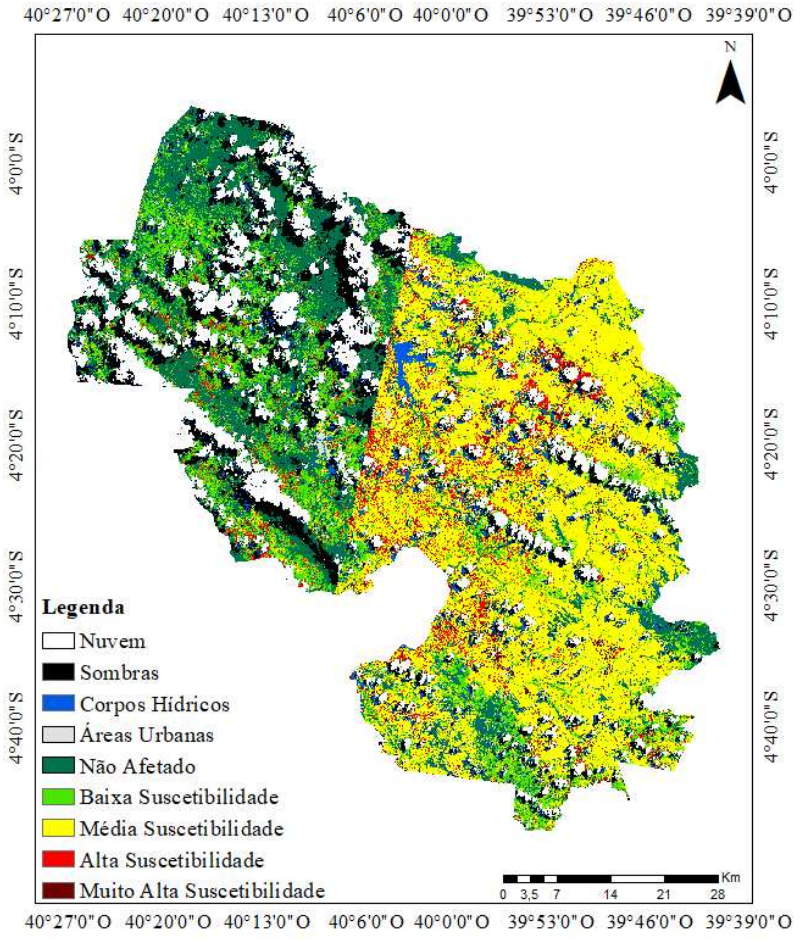

Fonte: Elaboração Própria; IGSD: Índice Geométrico de Suscetibilidade a Desertificação.

Figura 21 - Mapa de IGSD em Santa Quitéria (redes neurais – normalizado – 2011FS)

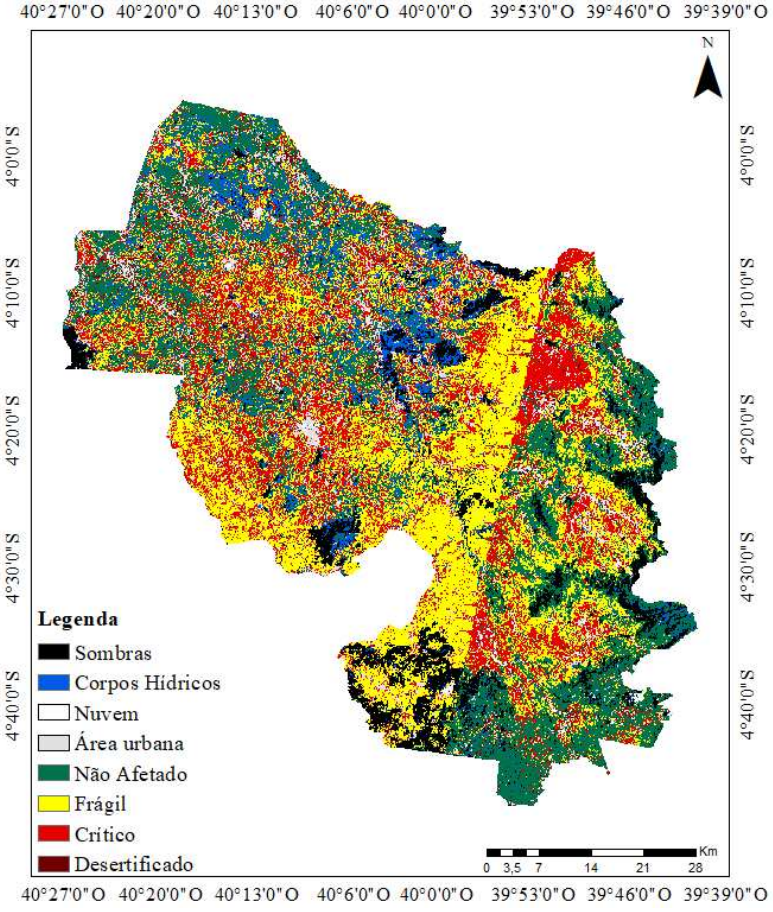

Figura 22 - Mapa de IGSD em Santa Quitéria (*Support Vector Machine* – normalizado – 2016FC)

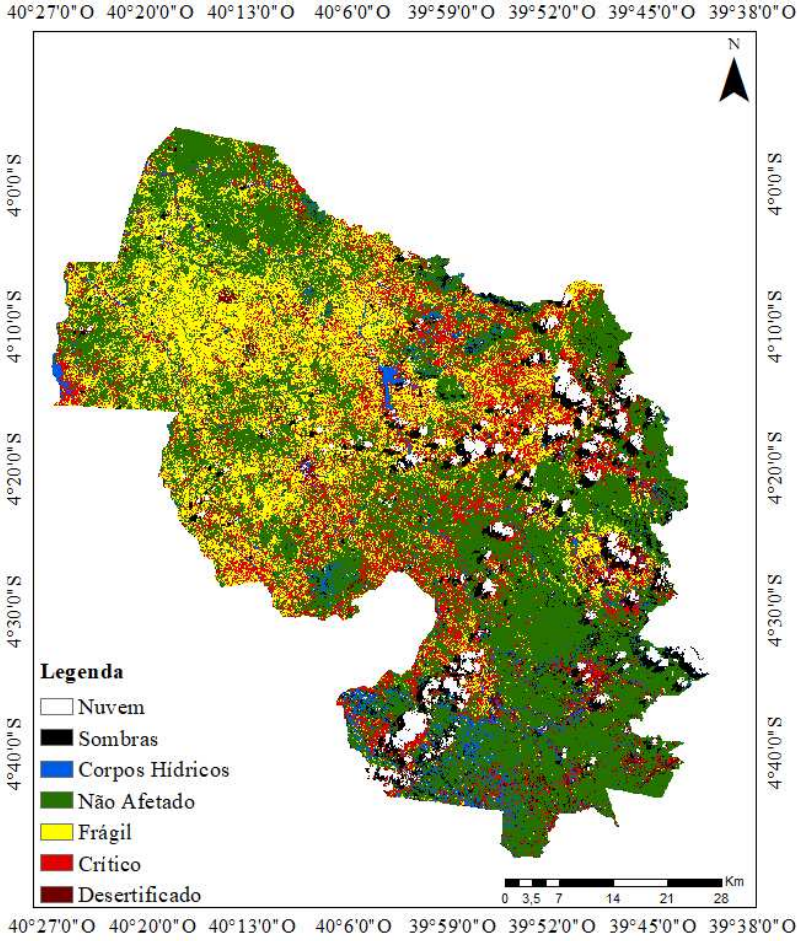

Fonte: Elaboração Própria; IGSD: Índice Geométrico de Suscetibilidade a Desertificação.

As áreas não afetadas estão localizadas em zonas de uso sustentável dos domínios dos sertões de Santa Quitéria e Sobral/Taperuaba apresentam superfícies moderadamente dissecadas a pedi planadas, respectivamente, com precipitações entre 560 a 850 mm; os domínios das Serras do Machado e vertente setentrional das Serras das Matas apresentam superfícies dissecadas e precipitações superiores a 740 mm.

O uso e ocupação baseia-se na exploração agropecuária sustentável em solos e biodiversidades parcialmente conservados com capacidade produtiva dos recursos naturais em condições equilibradas. Nestas áreas verificam-se menores intervenções antrópicas, pois, entre 2000 a 2018 as áreas ocupadas por pastagens e pastagens degradadas reduziram em 41,64% e 58,34%, respectivamente (FUNCEME, 2015; SOUZA *et al*., 2020).

As áreas potenciais e de baixa suscetibilidade a desertificação estão localizadas em zonas de recuperação ambiental com dinâmica progressiva em áreas de sertões e de serras, apresentam solos férteis e parcialmente conservados, com caatinga e mata ciliar degradada pela alteração da vegetação original em razão da ocupação de agricultura de subsistência e pecuária extensiva. Entre 2000 a 2018 as áreas ocupadas por pastagens reduziram em 27,38% e a degradação destas em 53,24% (FUNCEME, 2015; SOUZA *et al*., 2020).

As áreas frágeis e de moderada suscetibilidade a desertificação estão localizadas em zonas de recuperação ambiental com dinâmicas regressivas em áreas de sertões e de serras, com solos e biodiversidades comprometidos, apresentando caatinga e mata ciliar degradada em razão do desmatamento para ocupação de pastagens extensivas e a degradação destas, as áreas ocupadas por pastagens e de pastagens degradadas entre 2000 a 2018 aumentaram em 43,12% e 5,2%, respectivamente (FUNCEME, 2015; SOUZA *et al*.,2020).

As áreas críticas, desertificadas, alta suscetibilidade e muito alta suscetibilidade estão localizadas desde zonas de recuperação ambiental com dinâmicas regressivas (críticas e alta suscetilidade) com solos e biodiversidade comprometidos; a áreas fortemente degradadas (desertificado e muito alta suscetibilidade) com solos e biodiversidade irreversivelmente comprometidos em domínios de sertões e de serras (FUNCEME, 2015). Na classe crítica, entre 2000 a 2018, as áreas ocupadas por pastagens aumentaram em 58,26% e de pastagens degradadas em 28,94%; em áreas desertificadas e de muito alta suscetibilidade, as áreas ocupadas por pastagens aumentaram em 57,02% e 25,15%, respectivamente; e de pastagens degradadas em 25,78% na classe desertificada (SOUZA *et al*., 2020).

O modelo de RLM mostrou que o aumento do NDVI e Índice de Aridez reduzem as médias do IGSD em 5,5% e 2,8%, respectivamente, em contrapartida o aumento da temperatura, evapotranspiração e TGSI aumentam a média do IGSD em 2%, e 1,9% e 2,3%,

respectivamente; o modelo RL mostrou que o aumento do TGSI, temperatura e evapotranspiração aumentam os riscos a desertificação em 99,99%, 61,49% e 99,78%, respectivamente; o modelo de redes neurais considerou o albedo, NDVI, TGSI e evapotranspiração como as variáveis mais importantes na predição da suscetibilidade a desertificação.

A pressão antrópica pelo aumento do desmatamento para ocupação de áreas de pastagens, agropecuária extensiva em solos com limitações de uso, pastagens degradadas e ausência de técnicas de manejo e conservação do solo e das biodiversidades acarretaram em alterações na cobertura vegetal afetando diretamente a superfície do solo e as condições de balanço de energia (Tabela 27).

Tabela 27 - Correlações entre os índices em Santa Quitéria

Índices	**Correlações**
NDVI x TGSI	-0,9391
NDVI x Albedo	-0,8109
NDVI x Temperatura	-0,6381
TGSI x Temperatura	0,8613
Temperatura x Precipitação	-0,5124
Temperatura x Evapotranspiração	0,5700

Fonte: Elaboração Própria.

Para as áreas não afetadas o uso sustentável dos solos e da biodiversidade, bem como as maiores precipitações em regiões serranas e a topografia que dificulta a presença antrópica contribuíram para manutenção de vegetação densa com NDVI entre 0,4381 a 0,7817, promovendo a proteção do solo a radiação solar e contribuindo para maiores adições de matéria orgânica no solo melhorando a sua agregação e retenção de umidade, reduzindo a erosão e consequentemente o albedo e TGSI. Cobertura vegetal densa absorve mais a radiação solar e reduz a perda de umidade do solo mantendo as temperaturas mais estáveis favorecendo ao maior fluxo de calor latente aumentando a probabilidade a precipitações e reduzindo o risco a desertificação (LI *et al*., 2022).

As áreas potencias e com baixa suscetibilidade a desertificação tiveram reduções nas áreas ocupadas por pastagens e pastagens degradadas apresentando NDVI entre 0,3179 a 0,5355 indicando desde vegetação rala a densa; contudo estudos da Funceme (2015) mostraram caatinga e mata ciliar degradada pela alteração da vegetação original em razão da ocupação de agricultura de subsistência e pecuária extensiva, a alteração da cobertura vegetal primária sem

levar em consideração as potencialidades e as limitações destas áreas pode acarretar em problemas de erosão no solo, remoção de matéria orgânica e nutrientes, reduzindo a capacidade agrícola destas áreas resultando em abandono de áreas com maior exposição a erosão podendo desencadear assoreamento de corpos hídricos.

As áreas frágeis, moderada suscetibilidade, críticas, alta suscetibilidade, desertificadas e muito alta suscetibilidade a desertificação, apresentaram maiores ocupações de áreas de pastagens e pastagens degradadas, reduzindo em 57,76% da média do NDVI em relação ao NDVI de áreas não afetadas e potencias.

A ocupação pelo pastoreio extensivo com altas de lotação em solos com restrições de uso, podem reduzir as condições do solo para suportar a vegetação resultando em aumento da erosão levando a perda de matéria orgânica e nutrientes, reduzindo a retenção de umidade, o que aumentou a média do albedo, TGSI e Temperatura em 32,04%, 39,52%, 28,62%, respectivamente, quando comparado com áreas não afetadas e potenciais.

De acordo com Ning *et al*. (2021) e Zolotokrylin *et al*. (2020) o aumento do albedo e temperatura influencia o microclima pela maior evapotranspiração de vegetação esparsa e conversão da radiação solar em fluxo de calor sensível favorecendo as trocas térmicas secas diminuindo as probabilidades de precipitações que mostraram reduções de 5,2% nas áreas desertificadas em relação as não afetadas, contribuindo para maior escassez hídrica e menor umidade do solo, menor cobertura vegetal, maior erosão, resultando em perda da capacidade agrícola e aumentando o risco a desertificação.

Os modelos RLM e SVM apresentaram bons desempenhos nas etapas de treinamento, validação e teste, produzindo mapas de IGSD com acurácias e kappas de boa consistência corroborando com os resultados de Li *et al*. (2022); contudo o RLM mostrou-se mais adequado em razão dos menores MEO, MEC e maiores MTAC seguido do RL indicando o potencial destes na predição de suscetibilidade a desertificação corroborando com os resultados de Salunkhe *et al*.(2018).

Os modelos de redes neurais e SVM foram menos assertivos em campo, permitindo inferir limitações em relação a capacidade destes na modelagem do conjunto de dados, autores como Feng *et al*. (2022) e Li *et al*. (2022) afirmam que são necessários mais tempos de treinamentos e avaliações de taxas de aprendizados para construção de modelos com boa capacidade de generalização e aprendizado.

Todos os modelos apresentaram confusão entre as classes, principalmente entre não afetada e potencial; desertificado e crítico, estas classes possuem atributos espectrais bastantes similares que conforme Jawak *et al*. (2015) dificulta uma melhor segregação quando se utiliza

classificadores que usam apenas o atributo espectral, sendo necessário o emprego de classificadores orientados a objetos que possam usar atributos do objeto classe relacionados a forma, cor, continuidade espacial e textura.

5.5 Irauçuba Centro Norte (Regional)

5.5.1 RLM, RL, redes neurais e SVM

O NDVI foi considerado pelo Garson como a variável mais importante na predição da desertificação, o RLM mostrou que o aumento da cobertura vegetal (NDVI) reduziu a média do IGSD em 4%. O albedo, evapotranspiração e temperatura contribuíram para que a média do IGSD aumentasse em 1,9%, 1,1% e 4,5%, respectivamente. De acordo com o modelo logístico a evapotranspiração, TGSI e o albedo aumentaram os riscos a desertificação entre 51,32% a 99,99%; pouco mais de 1% do risco a desertificação foi reduzido em razão do aumento da precipitação (Tabela 28).

Tabela 28 - Índices e contribuições nas médias do IGSD e no risco a desertificação em Irauçuba Centro Norte

Local	RLM		RL	Redes Neurais
	Variáveis	**IGSD %**	**Risco (%)**	**(Garson Algoritmo)**
Irauçuba Centro Norte	NDVI	-4*	NS	35
	TGSI	NS	79,49*	20
	Albedo	1,92*	99,99*	22
	Evapotranspiração	1,18*	51,32*	18
	Temperatura	4,54*	NS	8
	Índice de Aridez	NS	NS	3
	Precipitação	NS	1,09*	4

Fonte: Elaboração Própria; * p – value<0,05; NS: não significativo – p – value>0,05; RLM – 1999FC: R^2: 0,7550; RL - 2001FC: R^2 Nagelkerke: 0,8770; Redes Neurais - 2000FS: R^2: 0,9649; sinal (-) indica redução em escala de percentual na média do IGSD.

O RLM e o RL mostraram menores desempenhos quanto a capacidade de explicarem a variabilidade do IGSD, em ambas as fases o RLM mostrou-se com R^2 baixo resultando em predições com maiores RMSE. Os modelos de redes neurais e SVM mostraram maiores R^2 nas etapas de validação e teste, em razão disso as predições de IGSD apresentaram menores RMSE (Tabela 29).

Tabela 29 - Métricas dos modelos nas fases de validação e teste em Irauçuba Centro Norte

Modelo	Período	Validação			Teste		
		R^2	R	RMSE	R^2	R	RMSE
RLM	1999FC	0,5095	0,7138	0,0127	0,3088	0,5557	0,2096
RL	2001FC	0,1442	-	-	0,092	-	-
Redes Neurais	2000FS	0,9649	0,9822	0,0166	0,5923	0,7696	0,1558
SVM	2001FC	0,9406	0,9698	0,04	0,6178	0,786	0,0748

Fonte: Elaboração Própria; RL: Regressão Logística - R^2 Nagelkerke.

O RLM, simultaneamente, subestimou a classe crítica e superestimou a classe não afetado, em razão do menor poder explicativo do modelo na etapa de teste cujas as predições mostraram maiores RMSE levando a estimativas fora dos intervalos de IGSD convencional (Tabela 29). A rede neural classificou a classe frágil como potencial e o SVM as classes não afetadas e potencial como frágil (Tabela 30).

Tabela 30 - Desempenho do RLM, Redes Neurais e SVM nas etapas de validação e teste em Irauçuba Centro Norte

Modelo	Subestimativa		Superestimativa	
	IGSD Convencional	IGSD Subestimado	IGSD Convencional	IGSD Superestimado
RLM	1,4142 - 1,8612 (C, D)	1,3161 - 1,7165 (F, C, D)	1,00 - 1,1892 (NA, P)	1,1797 - 1,3048 (P, F)
Redes Neurais	1,1698 - 1,2915 (NA, P, F)	0,7085 - 1,2008 (NA, P)	-	-
SVM	-	-	1,1698 - 1,2689 (NA, P, F)	1,2396 - 1,2754 (F)

Fonte: Elaboração Própria; (-): não houve estimativas abaixo e acima do IGSD convencional.

Os melhores mapas foram obtidos do RLM e RL mostrando serem de boa consistência, sendo que o RL apresentou maior MTAC em relação aos demais que mostraram MTAC inferiores a 20%. O baixo desempenho do RLM, redes neurais e SVM nas médias de MTAC estão relacionados ao baixo R^2 na etapa de teste e maior RMSE para o RLM, enquanto que para as redes neurais e o SVM inferi-se a ocorrência de problemas relacionados com a capacidade de generalização dos modelos podendo apresentar *overfitting* ou *underfitting*, pois, na fase de validação o R^2 foi elevado, por outro lado, na fase de teste este reduziu consideravelmente, o que de acordo com Feng *et al*. (2022) e Li *et al*. (2022) é um indicativo de modelos mal treinados com limitação em sua capacidade de generalização e aprendizado (Tabela 31).

Tabela 31 - Métricas dos modelos testados em Irauçuba Centro Norte

Modelo	Irauçuba Centro Norte				
	Acurácia	**Kappa**	**MEO**	**MEC**	**MTAC**
RLM	77,28	0,728	37,36	34,73	19,99
RL	73,12	0,6795	37,91	43,75	24,99
Redes Neurais	63,71	0,5734	19,79	19,51	19,96
SVM	74,26	0,6685	44,4	48,83	19,98

MEO: média de erro de omissão (%); MEC: média de erro de comissão (%); MTAC: média de taxa de acerto de campo (%).

As menores MTAC podem ser justificadas pelas deficiências dos modelos em separar classes com respostas espectrais semelhantes, o menor R^2 na etapa de teste indica baixo poder preditivo dos modelos dificultando a predição do IGSD e aumentando a confusão entre as classes que dependem apenas do atributo espectral para sua separação, de acordo com Jawak *et al*. (2015) além de procurar melhorar o desempenho destes modelos é necessário fazer uso de elementos que possam caracterizar o objeto classe.

5.5.2 Mapas de IGSD em Irauçuba Centro Norte (RLM, RL, Redes Neurais e SVM)

Os mapas de IGSD para Irauçuba Centro Norte obtido pelos modelos de RLM, RL, Redes Neurais e SVM estão contidos nas figuras 23, 24, 25 e 26.

Figura 23 - Mapa de IGSD Irauçuba Centro Norte (regressão linear múltipla - 1999FC)

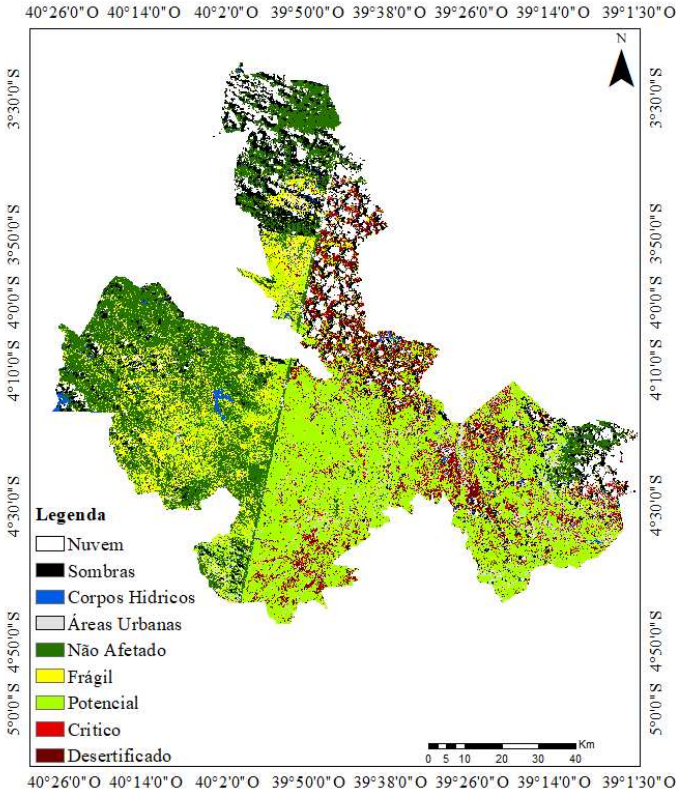

Figura 24 - Mapa de IGSD Irauçuba Centro Norte (regressão logística – 2001FC)

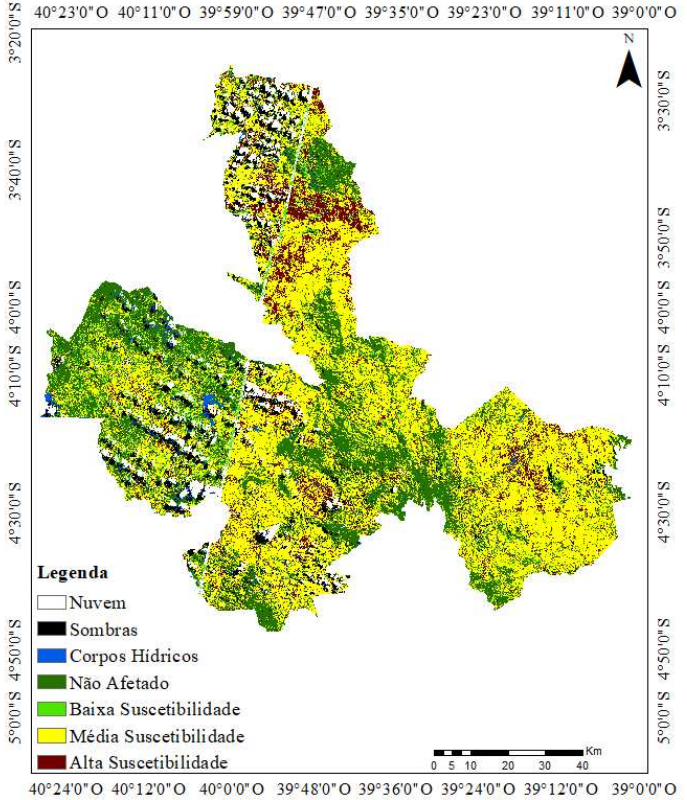

Fonte: Elaboração Própria; IGSD: Índice Geométrico de Suscetibilidade a Desertificação.

Figura 25 - Mapa de IGSD Irauçuba Centro Norte (redes neurais – 2000FS)

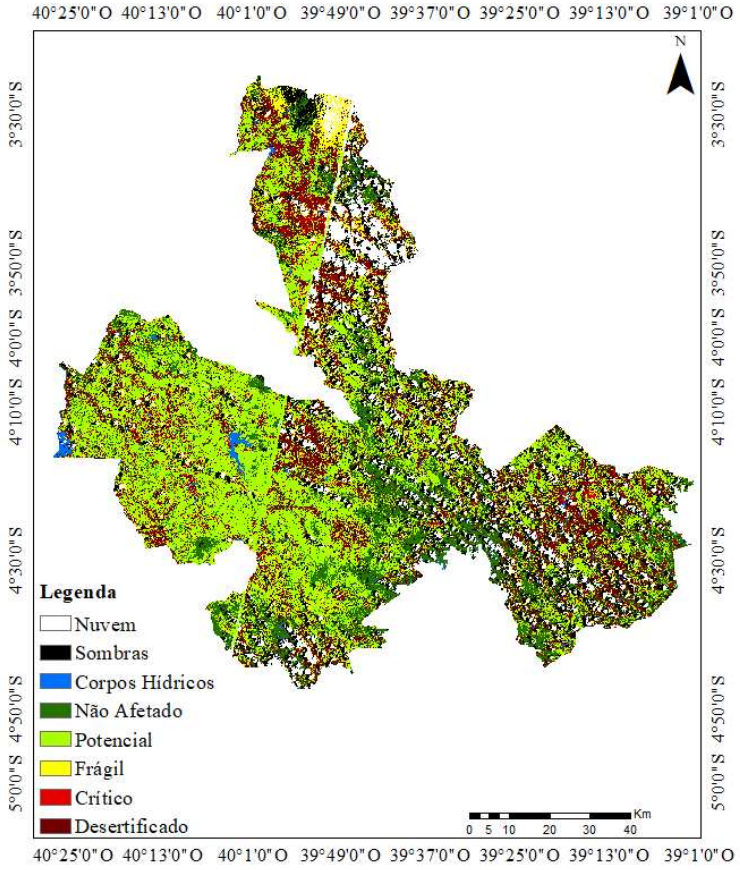

Figura 26 - Mapa de IGSD Irauçuba Centro Norte (*Support Vector Machine* – 2001FC)

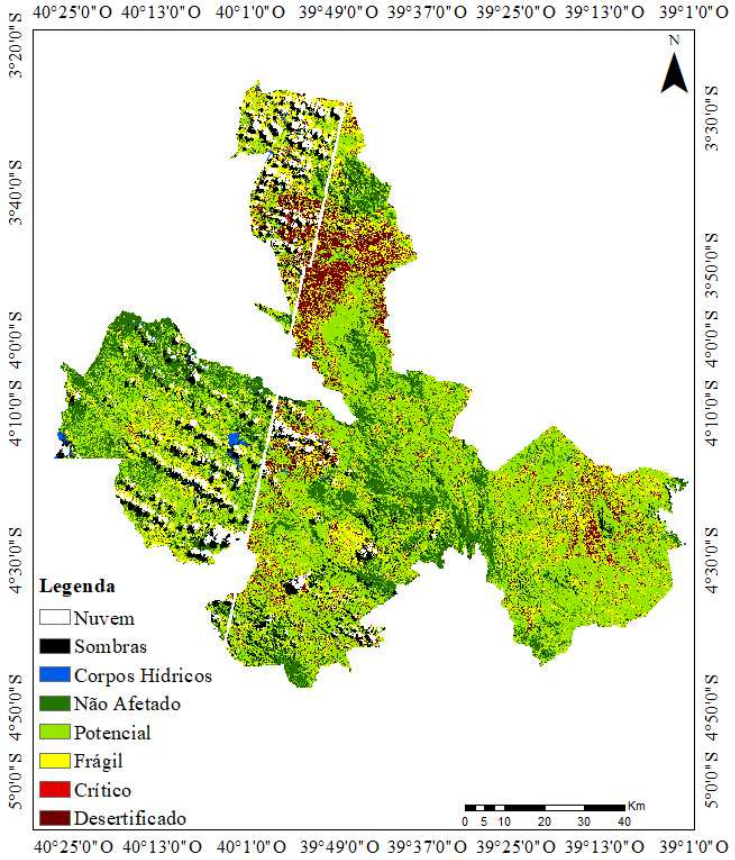

Fonte: Elaboração Própria; IGSD: Índice Geométrico de Suscetibilidade a Desertificação.

As áreas não afetadas estão localizadas em zonas de uso sustentável dos domínios dos Sertões de Sobral, Canindé, Santa Quitéria, Miraíma e de Irauçuba apresentando superfícies pedi planadas a moderadamente dissecadas com precipitações entre 560 a 850 mm; As áreas de serras são: Serras das Matas, Rosário, Machado, Uruburetama e de Baturité com precipitações entre 550 a 900 mm; apresentam solos e biodiversidades parcialmente conservados, com exploração agropecuária sustentável (FUNCEME, 2015).

O uso sustentável em áreas de serras e de sertões, as precipitações e declividades nos domínios de serras contribuíram para que os solos e a biodiversidade se mantenham em estado de equilíbrio com diferentes níveis de vegetação desde rala a densa permitindo condições favoráveis a não desertificação, entre 2010 a 2018 as áreas ocupadas por pastagens aumentaram em 25,78% contudo as áreas de pastagens degradadas reduziram em 5,6% (FUNCEME, 2015; SOUZA *et al*., 2020).

As áreas potenciais e de baixa suscetibilidade a desertificação estão localizadas em zonas de recuperação ambiental com dinâmica progressiva, ou seja, as atividades antrópicas existentes não comprometeram a qualidade do solo e dos recursos naturais, apresentando solos parcialmente conservados, com caatinga e mata ciliar degradada pela alteração da vegetação original em razão da ocupação de agricultura de subsistência e pecuária extensiva. Entre 2010 a 2018 as áreas ocupadas por pastagens aumentaram em 27,66% e a degradação destas reduziu em 10,61% (FUNCEME, 2015; SOUZA *et al*., 2020).

As áreas frágeis, críticas e desertificadas estão localizadas em zonas de recuperação ambiental com dinâmicas regressivas em áreas de sertões e de serras, caracterizam-se por apresentarem solos e biodiversidades comprometidos (Frágil e Crítico) e irreversivelmente comprometidos (desertificado) apresentando caatinga e a mata ciliar degradada em razão do desmatamento para ocupação de pastagens extensivas e a degradação destas. Na classe frágil as áreas ocupadas por pastagens e pastagens degradadas entre 2010 a 2018 aumentaram em 40,94% e 7,7%, respectivamente; em áreas críticas os aumentos foram de 56,10% e 25,56%, respectivamente e em áreas desertificadas de 43,02% e 14,94%, respectivamente (FUNCEME, 2015; SOUZA *et al*.,2020).

O modelo de RLM mostrou que o aumento do NDVI reduziu a média do IGSD em 4%, enquanto o aumento da temperatura, albedo e evapotranspiração aumentaram a média do IGSD em 4,5%, 1,9% e 1,1%, respectivamente; o modelo RL mostrou que o aumento do albedo, evapotranspiração e TGSI aumentaram os riscos a desertificação em 99,99%, 51,32% e 79,49%, respectivamente.

A pressão antrópica pelo o aumento do desmatamento para ocupação de áreas de

pastagens, agropecuária extensiva em solos com limitações de uso, pastagens degradadas e ausência de técnicas de manejo e conservação do solo e da biodiversidade acarretaram em reduções da cobertura vegetal afetando diretamente a superfície do solo e as condições de balanço de energia, (Tabela 32).

Tabela 32 - Correlações entre os índices de Irauçuba Centro Norte

Índices	Correlações
NDVI x Albedo	-0,8450
NDVI x TGSI	-0,5387
NDVI x Temperatura	-0,2809
TGSI x Temperatura	0,3850
Temperatura x Evapotranspiração	0,4763
Temperatura x Precipitação	-0,1639

Fonte: Elaboração Própria.

Para as classes não afetada, potencial e de baixa suscetibilidade, as áreas de pastagens degradadas diminuíram em razão do controle e fiscalização de atividades impactantes e o estabelecimento de técnicas de manejo sustentável dos solos e da biodiversidade, contribuindo para o NDVI entre 0,2272 a 0,7997 em áreas não afetadas e de 0,1780 a 0,4639 para áreas potencias indicando desde vegetação rala a densa, promovendo a proteção do solo a radiação solar e contribuindo para maiores adições de matéria orgânica no solo melhorando a sua agregação e retenção de umidade reduzindo a erosão e consequentemente o albedo e TGSI, cobertura vegetal densa absorve mais a radiação solar e reduz a perda de umidade do solo mantendo as temperaturas mais estáveis favorecendo ao maior fluxo de calor latente aumentando a probabilidade a precipitações e reduzindo o risco a desertificação (FUNCEME, 2015; LI *et al*., 2022).

As áreas frágeis, críticas e desertificadas apresentaram maiores ocupações de áreas de pastagens e pastagens degradadas, reduzindo em 33,27% da média do NDVI em relação ao NDVI de áreas não afetadas e potencias; a ocupação pelo pastoreio extensivo com altas taxas de lotação em solos com restrições de uso, acarretaram na compactação do solo e aumento da resistência a penetração das raízes, resultando em menor condição de suporte a vegetação, contribuindo para vegetação esparsa com áreas de solo exposto que aumentam os riscos a erosão, levando a perda de matéria orgânica e nutrientes, reduzindo a retenção de umidade, o que aumentou a média do albedo, TGSI e Temperatura em 29,56%, 12,64% e 12,69%, respectivamente, quando comparado com áreas não afetadas e potenciais.

De com Ning *et al*. (2021) e Zolotokrylin *et al*. (2020) o aumento do albedo e temperatura acarreta em alterações do microclima pela maior evapotranspiração de vegetação esparsa e conversão da radiação solar em fluxo de calor sensível favorecendo as trocas térmicas secas e diminuindo a probabilidade de precipitação, contribuindo para maior escassez hídrica e menor umidade do solo, menor cobertura vegetal, maior erosão, resultando em perda da capacidade agrícola e aumentando o risco a desertificação.

A boa acurácia e kappa dos modelos RL e RLM pode esta relacionado ao maior número de pontos analisados, já que, conforme Zhao *et al*. (2021) estes modelos mostram-se adequados para análises de grandes bases de dados, contudo para o RL o desbalanceamento de amostras das classes desertificadas e não desertificadas foi de 1:8,8, ou seja para cada 1 pixel desertificado haviam 8,8 não desertificados resultando em falhas do modelo logístico.

Todos os modelos apresentaram confusão entre as classes, principalmente entre não afetada, potencial e baixa suscetibilidade; desertificado e crítico, estas classes possuem atributos espectrais bastantes similares dificultando uma melhor segregação apenas com base na classificação pixel a pixel. De acordo com Jawak *et al*. (2015) é necessário a abordagem de classificação orientada a objeto com amostras de classes definidas não somente pelo atributo espectral, mas também, por atributos relacionados ao objeto como forma, cor, continuidade espacial e textura (JAWAK *et al.,* 2015).

6 CONCLUSÕES

Todos os modelos paramétricos e não paramétricos são capazes de predizerem a suscetibilidade a desertificação, identificando e quantificando o efeito de mudanças da vegetação, clima e solo elementos causadores do aumento do risco a desertificação a nível local e regional.

A avaliação da suscetibilidade a desertificação no final do período chuvoso mostra-se mais adequado em razão da maior variabilidade explicada pelos modelos.

O desempenho dos modelos paramétricos e não paramétricos é afetado pela dimensão espacial das áreas.

O RLM e o RL mostram-se promissores para uso em escala local e regional, enquanto que a rede neural e o SVM apenas a nível local.

O desmatamento para ocupação de áreas de pastagens e sua degradação levaram a redução da cobertura vegetal, mudanças no albedo, aumento de temperatura e evapotranspiração, fatores estes causadores da desertificação.

A classificação da suscetibilidade à desertificação baseada na informação espectral pixel a pixel mostrou-se adequada, contudo, sugere-se que em estudos futuros atente-se para o uso de classificadores que explorem os aspectos relacionados com o objeto classe de suscetibilidade a desertificação.

REFERÊNCIAS

ALLEN, R.; TASUMI, M.; TREZZA, R. SEBAL (Surface Energy Balance Algorithms for Land) – Advanced Training and Users Manual - Idaho Implementation, version 1.0, 2002, 98p.

AN, H.; TANG, Z.; KEESSTRA, S.; SHANGGUAN, Z. Impact of desertification on soil and plant nutrient stoichiometry in a desert grassland. **Scientific Reports.**, v. 9, p.1-8, 2019.

AZARI, M.; TAYYEBI, A.; HELBICH, M.; REVESHTY, M.A. Integrating cellular automata, artificial neural network, and fuzzy set theory to simulate threatened orchards: application to maragheh, iran. **Giscience & Remote Sensing.,** v. 53, p. 1-20, 2016.

BASTIAANSSEN, W. G. M.; MENENTI, M.; FEDDES, R. A.; HOLSLAG, A. A. M. A. Remote sensing surface energy balance algorithm for land (SEBAL) - Formulation. **Journal of Hydrology.,** v. 212, p.198 - 212, 1998.

BASTIAANSSEN, W.G.M. **Regionalization of surface flux densities and moisture indicators in composite terrain**. Tese (Ph.D), Wageningem Agricultural University, Wageningen: Netherlands, 273f, 1995.

BOULILA, W.; SELLAMI, M.; DRISS, M.; AL-SAREM, M.; SAFAEI, M.; GHALEB, F.A. RS-DCNN: a novel distributed convolutional-neural-networks based-approach for big remote-sensing image classification. **Computers And Electronics In Agriculture.,**v. 182, p. 1 - 13, 2021.

BUCKLAND, C. E.; BAILEY, R. M.; THOMAS, D. S. G. Using artificial neural networks to predict future dryland responses to human and climate disturbances. **Scientific Reports.,** v. 9, p.1-13, 2019.

CAPOZZI, F.; PALMA, A.D.; PAOLA, F.D.; GIUGNI, M.; IAVAZZO, P.; TOPA, M.E.; ADAMO, P.; GIORDANO, S. Assessing desertification in sub-Saharan peri-urban areas: Case study applications in Burkina Faso and Senegal. **Journal Of Geochemical Exploration.**, v. 190, p.281-291, 2018.

CEARÁ, Secretaria dos Recursos Hídricos. **Programa de Ação Estadual de Combate à Desertificação e Mitigação dos Efeitos da Seca, PAE – CE**. Fortaleza: Ministério do Meio Ambiente Secretaria dos Recursos Hídricas, 2010.

CEARÁ. Secretaria de Planejamento e Coordenação – SEPLAN. **Atlas do Ceará**. Fortaleza: Ed. IPLANCE, 1997.

CERVANTES, J.; GARCIA-LAMONT, F.; RODRÍGUEZ-MAZAHUA, L.; LOPEZ, A. A. comprehensive survey on support vector machine classification: applications, challenges and trends. **Neurocomputing.,** v. 408, p. 189-215, 2020.

CHAPUNGU, L.; NHAMO, L.; GATTI, R.C. Estimating biomass of savanna grasslands as a proxy of carbon stock using multispectral remote sensing. Estimating biomass of savanna grasslands as a proxy of carbon stock using multispectral remote sensing. **Remote Sensing**

Applications: **Society and Environment.,** v. 17, p.1-10, 2020.

CHANDER, G.; MARKHAN, B. Revised Landsat 5 - TM radiometric calibration procedures and post calibration dynamic ranges. **IEEE Transactions on Geosciences and Remote Sensing.,** v. 41, p.2674-2677, 2003.

CLARK, W.; HOSKING, P. **Statistical Methods for Geographers**. John Wiley & Sons: New York, NY, USA, 1986.

DJEDDAOUI, F.; CHADLI, M.; GLOAGUEN, R. Desertification Susceptibility Mapping Using Logistic Regression Analysis in the Djelfa Area, Algeria. **Remote Sensing.,** v. 9, p. 1-26, 2017.

EMADODIN, I.; REINSCH, T.; TAUBE, F. Drought and Desertification in Iran. **Hydrology.,** v. 6, p.1-12, 2019.

FANJUL-HEVIA, A.; GONZÁLEZ-MANTEIGA, W.; PARDO-FERNÁNDEZ, J. C. A non-parametric test for comparing conditional ROC curves. **Computational Statistics & Data Analysis.,** v. 157, p. 1-20, 2021.

FATHIZAD, H.; ARDAKANI, M.A.H.; MEHRJARDI, R.T.; SODAIEZADEH, H. Evaluating desertification using remote sensing technique and object-oriented classification algorithm in the Iranian central desert. **Journal Of African Earth Sciences.,** v. 145, p. 115-130, 2018.

FÁVERO, L.P.L.; BELFIORE, P.P. **Manual de análise de dados: estatística e modelagem multivariada com excel, SPSS e stata**. Rio de Janeiro: Elsevier, 2017.

FENG, K.; WANG, T.; LIU, S.; YAN, C; KANG, W.; CHEN, X.; GUO, Z. Path analysis model to identify and analyse the causes of aeolian desertification in Mu Us Sandy Land, China. **Ecological Indicators.,** v. 124, p. 1-10, 2021.

FERREIRA, M. P. S.; ARTHUR, A.G. Changes in attributes of soils subjected to fallow in desertification hotspot. **Revista Ciência Agronômica.**, v. 49, p.22-31, 2018.

FERREIRA, D. G.; MELO, H. P.; RODRIGUES NETO, F. R.; NASCIMENTO, P. J. S.; RODRIGUES, V. **Avaliação do Quadro da Desertificação no Nordeste do Brasil: Diagnósticos e Perspectivas**. p. 7-55, 1994.

FUNCEME. **Zoneamento Ecológico-Econômico das Áreas Susceptíveis à Desertificação do Núcleo I Irauçuba/Centro-Norte**. Fundação Cearense de Meteorologia e Recursos Hídricos – FUNCEME – Núcleo de Recursos Hídricos e Meio Ambiente – NUHRA. Fortaleza, 2015.

GARSON, G. D. Interpreting neural network connection weights. **Artificial Intelligence Expert.,** v. 6, p.46 – 51, 1991.

GHAYOUR, L.; NESHAT, A.; PARYANI, S.; SHAHABI, H.; SHIRZADI, A.; CHEN, W.; AL-ANSARI, N.; GEERTSEMA, M.; AMIRI, M.P.; GHOLAMNIA, M. Performance Evaluation of Sentinel-2 and Landsat 8 OLI Data for Land Cover/Use Classification Using a Comparison between Machine Learning Algorithms. **Remote Sensing.,** v. 13, p. 1-21, 2021.

GHOLAMI, V.; SAHOUR, H.; AMRI, M.A.H. Soil erosion modeling using erosion pins and artificial neural networks. **Catena.,** v. 196, p. 1 - 11, 2021.

GISLADOTTIR, G.; STOCKING, M. Land degradation control and its global environmental benefits. **Land Degradation & Development.,** v. 16, p.99-112, 2005.

GUERRA, M.D.F.; SOUZA, M. J. N.; LUSTOSA, J.P. G. A Pecuária, o algodão e a desertificação nos Sertões do Médio Jaguaribe – Ceará/Brasil. **Mercator.**, v. 11, p.103-112, 2012.

GUO, B.; ZANG, W.; HAN, B.; YANG, F.; LUO, W.; HE, T.; FAN, Y.; YANG, X.; CHEN, S. Dynamic monitoring of desertification in Naiman Banner based on feature space models with typical surface parameters derived from Landsat images. **Land Degradation & Development.**, v.31 p.1-20, 2019.

HAFEEZ, S.; WONG, M.; HO, H.; NAZEER, M.; NICHOL, J.; ABBAS, S.; TANG, D.; LEE, K.; PUN, L. Comparison of Machine Learning Algorithms for Retrieval of Water Quality Indicators in Case-II Waters: a case study of hong kong. **Remote Sensing.,** v. 11, p. 1-23, 2019.

HAN, J.; WANG, J.; CHEN, L.; XIANG, J.; LING, Z.; LI, Q.; WANG, E. Driving factors of desertification in Qaidam Basin, China: an 18-year analysis using the geographic detector model. **Ecological Indicators.,** v. 124, p. 1 -13, 2021.

HANDELMAN, T.; CHOR, B. Cases in which ancestral maximum likelihood will be confusingly misleading. **Journal Of Theoretical Biology.,** v. 420, p. 318-323, 2017.

HUANG, S.; ZHENG, X.; MA, L.; WANG, H.; HUANG, Q.; LENG, G.; MENG, E.; GUO, Y. Quantitative contribution of climate change and human activities to vegetation cover variations based on GA-SVM model. **Journal Of Hydrology.,** v. 584, p. 1-10, 2020.

IPECE. **Perfil Básico Municipal**. Instituto de Pesquisa e Estratégia Econômica do Ceará – IPECE. Fortaleza, 2009.

IPECE. **Perfil Básico Municipal**. Instituto de Pesquisa e Estratégia Econômica do Ceará – IPECE. Fortaleza, 2017.

JALAL, M.; ARABALI, P.; GRASLEY, Z.; BULLARD, J.W.; JALAL, H. Behavior assessment, regression analysis and support vector machine (SVM) modeling of waste tire rubberized concrete. **Journal Of Cleaner Production.,** v. 273, p. 1-15, 2020.

JAWAK, S.D.; DEVLIYAL, P.; LUIS, A.J. A. Comprehensive Review on Pixel Oriented and Object Oriented Methods for Information Extraction from Remotely Sensed Satellite Images with a Special Emphasis on Cryospheric Applications. **Advances In Remote Sensing.,** v. 04, p. 177-195, 2015.

JIANG, L.; JIAPAER, G.; BAO, A.; KURBAN, A.; GUO, H.; ZHENG, G.; MAEYER, P. Monitoring the long-term desertification process and assessing the relative roles of its drivers in Central Asia. **Ecological Indicators.,** v. 104, p. 195-208, 2019.

JIANG, M.; LIN, Y. Desertification in the south Junggar Basin, 2000–2009: part ii. model development and trend analysis. **Advances In Space Research.**, v. 62, p. 16-29, 2018.

JOSEPH, O.; GBENGA, A.E.; LANGYIT, D.G. Desertification risk analysis and assessment in Northern Nigeria. **Remote Sensing Applications: Society and Environment.,** v. 11, p. 70-82, 2018.

KARAVITIS, C.A.; TSESMELIS, D.E.; OIKONOMOU, P.D.; KAIRIS, O.; KOSMAS, C.; FASSOULI, V.; RITSEMA, C.; HESSEL, R.; JETTEN, V.; MOUSTAKAS, N. A. desertification risk assessment decision support tool (DRAST). **Catena.,** v. 187, p. 1-14, 2020.

KARAMESOUTI, M.; PANAGOS, P.; KOSMAS, C. Model-based spatio-temporal analysis of land desertification risk in Greece. **Catena.,** v. 167, p.266-275, 2018.

KOSMAS, C.; KIRKBY, M.; GEESON, N. **Manual on Key Indicators of Desertification and Mapping Environmentally Sensitive Areas to Desertification.** European Commission, Energy, Environment and Sustainable Development, 1999.

LANDIS, J. R; KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics.,** v.33, p. 159-174, 1977.

LAUSCH, A.; SCHMIDT, A.; TISCHENDORF, L. Data mining and linked open data – New perspectives for data analysis in environmental research. **Ecological Modelling.,** v. 295, p.5-17, 2015.

LI, P.; CHEN, P.; SHEN, J.; DENG, W.; KANG, X.; WANG, G.; ZHOU, S. Dynamic Monitoring of Desertification in Ningdong Based on Landsat Images and Machine Learning. **Sustainability.,** v. 14, p. 1-35, 2022.

LI, D.; WANG, S.; YUAN, H.; DEYI, L. Software and applications of spatial data mining. **Data Mining and Knowledge Discovery.,** v. 6, p.84-114, 2016.

LI, X.; ZHANG, X.; XU, X. Precipitation and Anthropogenic Activities Jointly Green the China–Mongolia–Russia Economic Corridor. **Remote Sensing.,** v. 14, p. 1-28, 2022.

LI, D.J.; XU, D.Y.; DING, X.;WANG, Z.Y.; SONG, A.L. Changes of wind erosion climatic erosivity and vegetation dynamics response in northern China from 1981 to 2010. **Res. Soil Water Conserv.,** v. 25, p.15–20, 2018.

LI, G.; YU, L.; LIU, T.; JIAO, Y.; YU, J. Modeling Potential Impacts on Regional Climate Due to Land Surface Changes across Mongolia Plateau. **Remote Sensing.,**v. 14, p. 1 - 15, 2022.

LIU, L.; LI, X.Y.; SHI, P.J.; GAO, S.Y.; WANG, J.H.; TA, W.Q.; SONG, Y. LIU, M.X.; WANG, Z.; XIAO, B.L. Wind erodibility of major soils in the farming-pastoral ecotone of China. **Journal Of Arid Environments.,** v. 68, p.611-623, 2007.

LIU, Y.; HEUVELINK, G.B.M.; BAI, Z.; HE, P.; XU, X.; DING, W.; HUANG, S. Analysis of

spatio-temporal variation of crop yield in China using stepwise multiple linear regression. **Field Crops Research.,** v. 264, p. 1-12, 2021.

MAIA, J.C.L.; COSTA, F.R. Aplicação do "Sistema Básico de Indicadores para a Identificação e Monitoramento dos Processos de Desertificação na América Latina e Caribe" nos municípios de Francisco Dantas e Encanto-RN. **Geo temas.,** v.1, p.85 – 99, 2011.

MARCUZZO, F. F. N.; ANDRADE, L. R.; MELO, D. C. R. Métodos de Interpolação Matemática no Mapeamento de Chuvas do Estado do Mato Grosso. **Revista Brasileira de Geografia Física.,** v. 4, p. 793-804, 2011.

MARIN, A.M.P.; CAVALCANTE, A.M.B.; MEDEIROS, S.S.; TINÔCO, L.B.M.; SALCEDO, I.H. Núcleos de desertificação no semiárido Brasileiro: ocorrência natural ou antrópica? **Parc.Estrat.,** v.17, p.87 – 106, 2012.

MARTINS, M.A.;TOMASELLA,J.; RODRIGUEZ,D.A.; ALVALA, R.C.S.; GIAROLLA, A.; GAROFOLO,L.L.;JUNIOR,J.L.S.; PAOLICCHI,L.T.L.C. Improving drought management in the Brazilian semiarid through crop forecasting. **Agricultural Systems.,** v. 160, p.21-30, 2018.

MATALLO JUNIOR, H. **A desertificação no mundo e no Brasil**. In: SCHENKEL, C. S. e MATALLO JR, H (Org). Desertificação. Brasília: UNESCO, 2003.

MIAO, L.; MOORE, J.C.; ZENG, F.; LEI, J.; DING, J.; HE, B.; CUI, X. Footprint of Research in Desertification Management in China. **Land Degradation & Development.,** v. 26, p.450-457, 2015.

MIGUEZ, G.; XAVIER, A.E.; MACULAN, N. An evaluation of the bihyperbolic function in the optimization of the backpropagation algorithm. **International Transactions In Operational Research.,** v. 21, p. 835-854, 2014.

MOHAMMED, S.A.; DENBOBA, M.A. Study of Soil Seed Banks in Ex-closures for Restoration of Degraded Lands in the Central Rift Valley of Ethiopia. **Scientific Reports.,** v. 10, p.1-9, 2020.

NAGELKERKE, N. J. D. A note on a general definition of the coefficient of determination. **Biometrika.,** v. 78, p. 691-692, 1991.

NHU, V.H.; SHIRZADI, A.; SHAHABI, H.; SINGH, S.K.; AL-ANSARI, N.; CLAGUE, J.J.; JAAFARI, A.; CHEN, W.; MIRAKI, S.; DOU, J. Shallow Landslide Susceptibility Mapping: a comparison between logistic model tree, logistic regression, naïve bayes tree, artificial neural network, and support vector machine algorithms. **International Journal Of Environmental Research And Public Health.,** v. 17, p. 1-30, 2020.

NING, Z.; ZHAO, X.; LI, Y.; WANG, L.; LIAN, J.; YANG, H.; LI, Y. Plant community C: n. **Ecological Engineering.,** v. 162, p. 1-12, 2021.

NORMAN, L.M.; LAL, R.; WOHL, E.; FAIRFAX, E.; GELLIS, A.C.; POLLOCK, M.M. Natural infrastructure in dryland streams (NIDS) can establish regenerative wetland sinks that reverse desertification and strengthen climate resilience. **Science Of The Total**

Environment., v. 849, p. 1 - 20, 2022.

PEREZ-MARIN, A. M.; VENDRUSCOLO, J.; ZÁRATE-SALAZAR, J.R.; QUEIROZ, H.A. A.; MAGALHÃES, D.L.; MENEZES, R.S. C.; FERNANDES, I. M.; Monitoring Desertification Using a Small Set of Biophysical Indicators in the Brazilian Semiarid Region. **Sustainability.,** v. 14, p. 1-24, 2022.

PI, W.; DU, J.; BI, Y.; GAO, X.; ZHU, X. 3D-CNN based UAV hyperspectral imagery for grassland degradation indicator ground object classification research. **Ecological Informatics.,** v. 62, p. 1 - 12, 2021.

PRADHAN, B. Remote sensing and GIS-based landslide hazard analysis and cross-validation using multivariate logistic regression model on three test areas in Malaysia. **Advances In Space Research.,** v. 45, p. 1244-1256, 2010.

QI, X.; ZHANG, C.; WANG, K. Comparing Remote Sensing Methods for Monitoring Karst Rocky Desertification at Sub-pixel Scales in a Highly Heterogeneous Karst Region. **Scientific Reports.,** v. 9, p. 1-12, 2019.

RAMPONE, S.; VALENTE, A. Assessment of desertification vulnerability using soft computing methods. **Journal Of Ambient Intelligence And Humanized Computing.,** v. 10, p. 701-707, 2018.

RANDIN, C.F.; ASHCROFT, M.B.; BOLLIGER, J.; CAVENDER-BARES, J.; COOPS, N.C.; DULLINGER, S.; DIRNBÖCK, T.; ECKERT, S.; ELLIS, E.; FERNÁNDEZ, N. Monitoring biodiversity in the Anthropocene using remote sensing in species distribution models. **Remote Sensing Of Environment.,** v. 239, p. 1-18, 2020.

REICHERT, J.M.; AMADO,T.J.C.; REINERT, D.J.; RODRIGUES, M.F.; SUZUKI,L.E.A.S. Land use effects on subtropical, sandy soil under sandyzation/desertification processes. **Agriculture, Ecosystems & Environment.,** v. 233, p.370-380, 2016.

ROUSE, J.W.; HAAS, R.W.; DEERING, D.W.; SCHELL, J.A.; HARLAN, J.C. **Monitoring the Vernal Advancement and Retrogradation (Greenwave Effect) of Natural Vegetation**. NASA/GSFC Type III Final Report, Greenbelt, MD, p. 371, 1974.

RODRIGUES, M.I.V.; VIANA, M.O. L. **Desertificação e construção de um coeficiente interdisciplinar para o estado do Ceará**.p. 66-95, 1997.

SALUNKHE, S.; BERA, A.K.; RAO, S.; VENKATARAMAN, V.; RAJ, U.; MURTHY, Y. V. N. K. Evaluation of indicators for desertification risk assessment in part of Thar Desert Region of Rajasthan using geospatial techniques. **Journal Of Earth System Science.,**v. 127, p. 1-24, 2018.

SALVATI, L.; BAJOCCO, S. Land sensitivity to desertification across Italy: Past, present, and future. **Applied Geography.,** v. 31, p.223-231, 2011.

SALVATI, L.; KOSMAS, C.; KAIRIS, O.; KARAVITIS, C.; ACIKALIN, S.; BELGACEM, A.; SOLÉ-BENET, A.; CHAKER, M.; FASSOULI, V.; GOKCEOGLU, C. Assessing the effectiveness of sustainable land management policies for combating desertification: a data

mining approach. **Journal Of Environmental Management.,** v. 183, p. 754-762, 2016.

SALVIA, R.; EGIDI, G.; VINCI, S.; SALVATI, L. Desertification Risk and Rural Development in Southern Europe: Permanent Assessment and Implications for Sustainable Land Management and Mitigation Policies. **Land.,** v. 8, p.1-16, 2019

SHARMA, L.K.; RAJ, A.; SOMAWAT, K. Spatio-temporal assessment of Environmentally Sensitive Areas (ESA) in The Thar Desert India, to combat desertification under UNCCD framework. **Journal Of Arid Environments.,** v. 194, p. 1-17, 2021.

SILVA, I.A.S.; BARROS, J.R.; SUERTEGARAY, D.M.A. Variabilidade climática e seus efeitos no processo de arenização em Gilbués - Piauí. **Revista REGNE.,** v. 2, p. 406 – 415, 2016.

SOUSA, F.P.; FERREIRA, T.O.; MENDONÇA, E.S.; ROMERO, R.E.; OLIVEIRA, J.G.B. Carbon and nitrogen in degraded Brazilian semi-arid soils undergoing desertification. **Agriculture, Ecosystems & Environment.,** v.148, p.11-21, 2012.

SOUZA, C.M.; SHIMBO, J.Z.; ROSA, M.R.; PARENTE, L.L.; ALENCAR, A.A.; RUDORFF, B.F. T.; HASENACK, H.; MATSUMOTO, M.; FERREIRA, L.G.; SOUZA-FILHO, P.W.M. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing.,** v. 12, p. 1- 27, 2020.

STEADMAN, R.G. The assessment of sultriness. Part I: A temperature-humidity index based on human physiology and clothing science. **Journal of Climate and Applied Meteorology.,** v.18, p.861-873, 1979.

TELLMAN, B.; MAGLIOCCA, N.R.; TURNER, B. L.; VERBURG, P. H. Understanding the role of illicit transactions in land-change dynamics. **Nature Sustainability.,** v. 3, p. 175-181, 2020.

THORNTHWAITE, C.W. An approach toward a rational classification of climate. **Geographical Review.,** v.38, p.55-94, 1948.

TOMASELLA, J.; VIEIRA, R.M.S.P.; BARBOSA, A.A.; RODRIGUEZ, D.A.; SANTANA, M.O.; SESTINI, M.F. Desertification trends in the Northeast of Brazil over the period 2000–2016. **International Journal Of Applied Earth Observation And Geoinformation.,** v. 73, p.197-206, 2018.

UZUNER, C.; DENGIZ, O. Desertification risk assessment in Turkey based on environmentally sensitive areas. **Ecological Indicators.,** v. 114, p. 1-12, 2020.

VAPNIK, Vladimir. **The Nature of Statistical Learning Theory**. Springer, 1998.

VIEIRA, R.M.S.P.; SESTINI, M.F.; TOMASELLA, J.; MARCHEZINI, V.; PEREIRA, G.R.; BARBOSA, A.A.; SANTOS, F.C.; RODRIGUEZ, D.A.; NASCIMENTO, F.R.; SANTANA, M.O. Characterizing spatio-temporal patterns of social vulnerability to droughts, degradation and desertification in the Brazilian northeast. **Environmental And Sustainability Indicators.,** v. 5, p.1-9, 2020.

VIEIRA, R. M. S. P.; TOMASELLA, J.; ALVALÁ, R.C.S.; SESTINI, M.F.; AFFONSO, A.G.; RODRIGUEZ, D.A.; BARBOSA, A.A.; CUNHA, A.P.M.A.; VALLES, G.F.; CREPANI, E.; OLIVEIRA, OLIVEIRA, S.B.P.; SOUZA, M.S.B.; CALIL,P.M.; CARVALHO, M.A.; VALERIANO, D.M.; CAMPELLO, F.C.B.; SANTANA, M.O. Identifying areas susceptible to desertification in the Brazilian northeast. **Solid Earth., v.** 6, p.347-360, 2015.

WANG, F.; SHI, Z.; BISWAS, A.; YANG, S.; DING, J. Multi-algorithm comparison for predicting soil salinity. **Geoderma.,** v. 365, p. 1-18, 2020.

WANG, W.; EVAN, A.T.; FLAMANT, C.; LAVAYSSE, C. **On the decadal scale correlation between African dust and Sahel rainfall: The role of Saharan heat low–forced winds**. 2015.

XIAO, J.; SHEN, Y.; TATEISHI, R. Development of topsoil grain size index for monitoring desertification in arid land using remote sensing. Int J. **Remote Sens.,** v. 27, p.2411–2422, 2006.

XU, D.; YOU, X.; XIA, C. Assessing the spatial-temporal pattern and evolution of areas sensitive to land desertification in North China. **Ecological Indicators.,** v. 97, p. 150-158, 2019.

XU, E.Q.; ZHANG, H.Q.; LI, M.X. Object-Based Mapping of Karst Rocky Desertification using a Support Vector Machine. **Land Degradation & Development.,** v. 26, p. 158-167, 2012.

ZHANG, C.; WANG, X.; LI, J.; HUA, T. Identifying the effect of climate change on desertification in northern China via trend analysis of potential evapotranspiration and precipitation. **Ecological Indicators.,** v. 112, p.1-9, 2020.

ZHANG, J.; HUANG, Y.; PU, R.; GONZALEZ-MORENO, P.; YUAN, L.; WU, K.; HUANG, W. Monitoring plant diseases and pests through remote sensing technology: A review. **Computers And Electronics In Agriculture.,** v. 165, p.1-14, 2019.

ZHAO, J.; HU, L.; DONG, Y.; HUANG, L. Hybrid Dense Network with Dual Attention for Hyperspectral Image Classification. **Remote Sensing.,** v. 13, p.1-22, 2021.

ZOLOTOKRYLIN, A.N.; BRITO-CASTILLO, L.; TITKOVA, T.B. Local climatically-driven changes of albedo and surface temperatures in the Sonoran Desert. **Journal Of Arid Environments.,** v. 178, p. 1 - 13, 2020.

APÊNDICE A – ESTATÍSTICA DESCRITIVA MIRAIMA

Local	Período	Índice	Média	Intervalo interquartílico	Desvio Padrão	CV (%)
Miraíma	2000FS	NDVI	0,2636	0,2112 – 0,3207	0,0965	36,63
		TGSI	0,1762	0,1340 – 0,2201	0,0601	34,13
		Albedo	0,1556	0,1057 – 0,1700	0,0894	57,47
		Temperatura	28,95	25,25 - 34,66	9,0430	31,23
		Evapotranspiração	0,2250	0,0698 – 0,3907	0,1991	88,49
		Precipitação	25,46	Indisponível	8,57	33,67
		Índice de Aridez	0,0194	Indisponível	0,0065	33,67
		IGSD	1,6715	1,5743 – 1,7381	0,0887	5,30
	2000FC	NDVI	0,4461	0,3704 – 0,5432	0,1274	28,55
		TGSI	0,2158	0,1924 – 0,2582	0,0595	27,56
		Albedo	0,0845	0,0738 - 0,0847	0,0377	44,65
		Temperatura	28,84	27,01 – 30,89	3,2955	11,42
		Evapotranspiração	0,3559	0,1953 – 0,4768	0,2455	68,98
		Precipitação	548,64	461,09 – 666,68	148,07	26,98
		Índice de Aridez	0,5402	0,4540 – 0,6565	0,1458	26,98
		IGSD	1,3401	1,2915 – 1,3685	0,0900	6,7181
	2003FS	NDVI	0,3059	0,2800 – 0,3475	0,0848	27,74
		TGSI	0,2524	0,2357 – 0,2791	0,0500	19,84
		Albedo	0,1116	0,1014 – 0,1182	0,0233	20,94
		Temperatura	34,47	27,01 – 30,89	3,2955	11,42
		Evapotranspiração	0,0558	Indisponível	0,1921	343,98
		Precipitação	733,31	646,98 - 825,30	170,85	23,29
		Índice de Aridez	0,3408	0,3007 – 0,3836	0,0794	23,29
		IGSD	1,4488	1,4320 – 1,4957	0,0653	4,5099
	2005FC	NDVI	0,2640	0,2018 - 0,3298	0,1058	40,07
		TGSI	0,2028	0,1130 - 0,2516	0,1269	62,58
		Albedo	0,1432	0,0886 – 0,1660	0,0717	50,10
		Temperatura	28,33	23 - 35	8,70	30,71
		Evapotranspiração	0,3767	0,1628 – 0,5276	0,2227	59,12
		Precipitação	305,88	195,63 – 400,71	160,45	52,46
		Índice de Aridez	0,2581	0,1650 – 0,5525	0,1354	52,45
		IGSD	1,503	1,426 – 1,6010	0,119	7,89
	2018FC	NDVI	0,4321	0,3803 – 0,5816	0,2218	51,33
		TGSI	0,1183	0,0834 – 0,1510	0,0602	50,95
		Albedo	0,1090	0,0815 – 0,1197	0,0817	75,00
		Temperatura	26,95	26,07 – 29,64	4,3563	16,15
		Evapotranspiração	0,0992	Indisponível	0,2562	258,14
		Precipitação	713,013	616,51 – 821,81	184,62	25,89
		Índice de Aridez	0,5329	0,4608 – 0,6142	0,1379	25,89
		IGSD	1,3341	1,2915 – 1,3685	0,0994	7,45

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; CV: Coeficiente de Variação; NDVI, TGSI, Albedo, Índice de Aridez e IGSD: Adimensional; Temperatura: C° (Celsius); Precipitação: mm (milímetros); Evapotranspiração: mm/h (milímetros por hora).

APÊNDICE B - MODELOS DE REGRESSÃO MÚLTIPLA EM MIRAÍMA

Períodos	Modelos	Treinamento			Validação	
		R^2	R	Pontos Amostrados	R^2	R
1997FC	$IGSD=1,636-0,785*_{NDVI}+0,002*_{Temperatura}+0,365*_{Evapotranspiração}-0,532*_{Índice\ de\ Aridez}$	0,742	0,862	37	0,6331	0,7957
1998FC	$IGSD=1,603-0,321*_{NDVI}-0,001*_{Precipitação}-0,428*_{Evapotranspiração}$	0,737	0,858	46	0,4541	0,6739
1999FC	$IGSD=1,235-0,153*_{NDVI}+0,234*_{Albedo}$	0,846	0,92	29	0,665	0,8154
2000FS	$IGSD=1,668-0,872*_{NDVI}+0,104*_{Evapotranspiração}+0,008*_{Temperatura}$	0,616	0,785	31	0,4528	0,6729
2000FC	$IGSD=1,374-0,321*_{NDVI}+0,710*_{Albedo}+0,117*_{Evapotranspiração}$	0,525	0,725	36	0,4743	0,6887
2001FC	$IGSD=1,128-0,367*_{NDVI}+0,013*_{Temperatura}+0,163*_{Evapotranspiração}$	0,571	0,756	34	0,5435	0,7372
2004FS	$IGSD=1,534-0,790*_{NDVI}+2,519*_{Albedo}+0,127*_{Evapotranspiração}+0,390*_{TGSI}$	0,794	0,891	46	0,4643	0,6814
2004FC	$IGSD=1,302-0,406*_{NDVI}+1,454*_{Albedo}+0,215*_{Evapotranspiração}$	0,675	0,822	25	0,6038	0,777
2005FS	$IGSD=1,510-0,338*_{NDVI}+0,117*_{Evapotranspiração}+0,009*_{Temperatura}$	0,405	0,637	45	0,4943	0,7031
2005FC[1]	$IGSD=1,200-0,576*_{NDVI}-0,280*_{Índice\ de\ Aridez}+0,309*_{Evapotranspiração}+0,743*_{Albedo}+0,012*_{Temperatura}$	0,795	0,891	29	0,7835	0,8851
2006FS	$IGSD=1,319+0,838*_{Albedo}+0,009*_{Temperatura}$	0,572	0,756	35	0,4784	0,6917
2006FC	$IGSD=1,519-0,348*_{NDVI}+4,567*_{Albedo}+0,105*_{Evapotranspiração}$	0,653	0,808	44	0,5007	0,7076
2008FS	$IGSD=1,172+0,309*_{Evapotranspiração}+0,022*_{Temperatura}-1,020*_{NDVI}+0,771*_{Albedo}$	0,879	0,938	30	0,6847	0,8275
2008FC	$IGSD=2,016-0,527*_{NDVI}-0,905*_{TGSI}+3,322*_{Albedo}-0,016*_{Temperatura}$	0,696	0,834	40	0,5242	0,724
2011FS	$IGSD=1,634-0,441*_{NDVI}+1,127*_{Albedo}+0,134*_{Evapotranspiração}$	0,714	0,845	44	0,3662	0,6051
2011FC	$IGSD=0,892-0,233*_{NDVI}+1,495*_{Albedo}+0,034*_{Evapotranspiração}$	0,756	0,87	44	0,4974	0,7052
2012FS	$IGSD=1,267-0,474*_{NDVI}+0,528*_{Albedo}+0,150*_{Evapotranspiração}+0,013*_{Temperatura}$	0,611	0,781	44	0,41	0,6403
2012FC	$IGSD=1,805-0,424*_{NDVI}+0,974*_{Albedo}-0,001*_{Precipitação}$	0,75	0,866	17	0,5815	0,7625
2013FC	$IGSD=2,031-0,471*_{NDVI}+1,856*_{Albedo}$	0,786	0,887	44	0,4926	0,7019
2014FC	$IGSD=1,901-0,486*_{NDVI}$	0,722	0,85	43	0,496	0,7042
2015FC	$IGSD=2,164-0,925*_{NDVI}-0,010*_{Temperatura}$	0,682	0,826	33	0,3359	0,5795
2016FC	$IGSD=1,558-0,809*_{NDVI}+0,141*_{Evapotranspiração}+0,007*_{Temperatura}$	0,707	0,841	22	0,5361	0,7322
2017FC	$IGSD=1,691-0,804*_{NDVI}$	0,602	0,776	24	0,5575	0,7466
2018FC	$IGSD=1,042-0,100*_{NDVI}+1,116*_{Albedo}+0,134*_{Evapotranspiração}+0,009*_{Temperatura}$	0,754	0,868	38	0,6459	0,8037

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; 2005FC[1]: modelo selecionado; data: 20/09/2005.

APÊNDICE C - MODELOS DE REGRESSÃO LOGÍSTICA EM MIRAÍMA

Período	Variável	βi	Exp(βi)	Treinamento			Validação			Amostras por Classe
				R^2 Nagelkerke	ROC	Taxa de Acerto (%)	R^2 Nagelkerke	ROC	Taxa de Acerto (%)	
2000FS[1]	NDVI	-59,546	~0	0,777	0,958	90	0,1824	0,634	65,21	D:21; D:25
	Evapotranspiração	10,304	29865,434							
	Temperatura	1,049	2,855							
2004FC	Evapotranspiração	18,516	infinito	0,754	0,97	96	0,3591	0,354	84,78	D:6; ND:40
	NDVI	-60,424	~0							
2005FS	Temperatura	0,658	1,93	0,556	0,889	80	0,3307	0,513	52,17	D:32; D:14
	Evapotranspiração	7,54	1881,978							
	NDVI	-36,095	~0							
2005FC	Temperatura	1,106	3,023	0,83	0,971	86	0,1759	0,354	43,47	D:22;ND:24
	Evapotranspiração	27,154	Infinito							
	Índice de Aridez	-21,913	~0							
	Albedo	114,525	infinito							
2006FS	Albedo	48,77	infinito	0,698	0,956	86	0,3909	0,612	63,04	D:32;ND:14
	Temperatura	0,595	1,813							
2012FS	Temperatura	0,429	1,536	0,56	0,874	82	0,2469	0,535	52,38	D:26;ND:16
2018FC	Albedo	37,9	infinito	0,522	0,9867	95,8	0,224	0,686	90,47	D:5;ND:37

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; ROC: (*receiver operator characteristic curve*); TA: taxa de acerto (%); 2000FS[1]: modelo selecionado; data: 25/11/2000.

APÊNDICE D - MODELOS DE REDES NEURAIS E SVM EM MIRAÍMA

Período	Modelos			
	Rede Neural		SVM	
	R^2	RMSE	R^2	RMSE
1997FC	0,9599	0,028	0,9280	0,0182
1998FC	0,9797	0,0099	0,9285	0,0125
1999FC	0,9732	0,0153	0,9535	0,0175
2000FS	0,9629	0,0167	0,9763	0,0077
2000FC[1]	0,9998	0,0015	0,9523	0,0219
2001FC	0,9025	0,0277	0,9194	0,0162
2003FS[2]	0,9770	0,0056	0,9935	0,0061
2004FS	0,9621	0,0128	0,9437	0,0095
2004FC	0,9383	0,0266	0,9657	0,0153
2005FS	0,9443	0,0122	0,9281	0,0086
2005FC	0,9671	0,0208	0,9335	0,0275
2006FS	0,9176	0,0127	0,9814	0,0061
2006FC	0,9860	0,0054	0,9587	0,0089
2007FC	0,9710	0,0118	0,9899	0,0114
2008FS	0,9777	0,0161	0,9604	0,0191
2008FC	0,9227	0,0135	0,9657	0,0097
2011FS	0,9216	0,0203	0,9589	0,0145
2011FC	0,9688	0,0062	0,9739	0,0097
2012FS	0,9886	0,0087	0,9444	0,0209
2012FC	0,9622	0,0161	0,9547	0,0182
2013FC	0,9875	0,0146	0,9664	0,0186
2014FC	0,9799	0,0038	0,9741	0,0056
2015FC	0,9593	0,0160	0,9596	0,0162
2016FC	0,9729	0,0130	0,9560	0,0162
2017FC	0,9842	0,0088	0,9442	0,0176
2018FC	0,9751	0,0185	0,9507	0,0228

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; 2000FC[1]: modelo de rede neural selecionado; data: 21/08/2000; 2003FS[2]: modelo de SVM selecionado; data: 18/11/2003.

APÊNDICE E – MATRIZ DE CONFUSÃO MODELOS DE MIRAÍMA

Modelo	Classificação	Referência				
		NA	P	F	C	Total
RLM	NA	1215	799	55	2	2071
	P	91	14826	4094	210	19221
	F	3	1459	3289	102	4853
	C	0	891	2421	2468	5780
	Total	1309	17975	9859	2782	31925

	Classificação	Referência					
		NA	BS	MS	AS	MAS	Total
RL	NA	27292	685	326	22	7	28332
	BS	151	894	59	7	1	1112
	MS	14163	5257	4799	502	189	24910
	AS	148	40	44	164	22	418
	MAS	538	1147	657	988	774	4104
	Total	42292	8023	5885	1683	993	58876

	Classificação	Referência					
		NA	P	F	C	D	Total
Redes Neurais	NA	90	117	10	3	3	223
	P	10	149	1208	880	96	2343
	F	0	22	4924	487	159	5592
	C	1	28	2149	2214	46	4438
	D	0	7	405	205	290	907
	Total	101	323	8696	3789	594	13503

	Classificação	Referência			
		P	F	C	Total
SVM	P	342	2531	129	3002
	F	14	10683	701	11398
	C	10	2868	658	3536
	Total	366	16082	1488	17936

Fonte: Elaboração própria; NA: não afetado; P: Potencial; F: Frágil; C: Crítico; D: Desertificado; BS: Baixa Suscetibilidade; MS: Moderada Suscetibilidade; AS: Alta Suscetibilidade; MAS: Muito Alta Suscetibilidade.

APÊNDICE F – ESTATÍSTICA DESCRITIVA CANINDÉ

Local	Período	Índice	Média	Intervalo Interquartílico	Desvio Padrão	CV (%)
Canindé	1997FC	NDVI	0,3069	0,2746 – 0,3541	0,0847	27,61
		TGSI	0,233	0,2160 - 0,2640	0,083	35,79
		Albedo	0,1372	0,0970 – 0,1440	0,0884	64,45
		Temperatura	28,07	24,69 - 34,66	8,56	30,51
		Evapotranspiração	0,3097	0 – 0,3217	0,2138	69,02
		Precipitação	188,86	24,96 – 348,74	164,5	8,1
		Índice de Aridez	0,0852	0,0103 – 0,1449	0,0683	80,21
		IGSD	1,5874	1,4501 – 1,6682	0,129	8,125
	1998FC	NDVI	0,36	0,2976 – 0,4150	0,0873	24,26
		TGSI	0,242	0,2170 – 0,2670	0,04	16,6
		Albedo	0,101	0,0820 - 0,1180	0,0282	27,96
		Temperatura	25,99	22,56 – 30,25	6,1502	23,65
		Evapotranspiração	0,1423	0 – 0,1199	0,1059	74,42
		Precipitação	148,2	19,33 - 264,27	131,48	88,71
		Índice de Aridez	0,065	0,0078 – 0,1067	0,0531	81,7
		IGSD	1,5365	1,4381 – 1,6682	0,146	9,504
	2006FC	NDVI	0,7288	0,6890 – 0,8182	0,1403	19,25
		TGSI	0,158	0,1180 – 0,1960	0,053	33,49
		Albedo	0,0919	0,0860 – 0,10	0,0145	15,8
		Temperatura	30,43	27,88 – 34,66	6,851	22,5
		Evapotranspiração	0,789	0 – 0,7840	0,3957	50,15
		Precipitação	715,6	672,80 - 778,10	136,2	19,04
		Índice de Aridez	0,5279	0,4963 – 0,5740	0,1004	19,03
		IGSD	1,3069	1,1699 – 1,4260	0,1504	11,51
	2018FC	NDVI	0,371	0,33 – 0,4130	0,0917	24,71
		TGSI	0,193	0,1850 – 0,2190	0,048	24,9
		Albedo	0,114	0,0940 – 0,1190	0,051	44,74
		Temperatura	28,22	24,23 – 33,54	7,0977	25,14
		Evapotranspiração	0,3784	0 – 0,4169	0,2549	67,37
		Precipitação	638,99	606,48 – 686,39	127,39	19,93
		Índice de Aridez	0,4776	0,4533 – 0,5130	0,0952	19,93
		IGSD	1,438	1,3686 - 1,5110	0,0895	6,2217

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; CV: Coeficiente de Variação; NDVI, TGSI, Albedo, Índice de Aridez e IGSD: Adimensional; Temperatura: C° (Celsius); Precipitação: mm (milímetros); Evapotranspiração: mm/h (milímetros por hora).

APÊNDICE G – MODELOS DE REGRESSÃO MÚLTIPLA EM CANINDÉ

Períodos	Modelos	Treinamento			Validação	
		R^2	R	Pontos Amostrados	R^2	R
1997FC[1]	$IGSD=1,444-0,645_{NDVI}+0,200_{Albedo}+0,013_{Temperatura}+0,215_{Evapotranspiração}-1,493_{Indice\ de\ Aridez}$	0,827	0,91	96	0,7615	0,8726
1998FC	$IGSD=1,380-0,635_{NDVI}+1,231_{Albedo}+0,011_{Temperatura}-1,508_{\ Indice\ de\ Aridez}+0,055_{Evapotranspiração}$	0,883	0,939	100	0,5886	0,7672
1999FC	$IGSD=1,334-0,329_{NDVI}+0,331_{\ Albedo}+0,010_{Temperatura}-0,749_{\ Índice\ de\ Aridez}$	0,818	0,904	155	0,427	0,6534
2000FS	$IGSD=1,432-0,607_{NDVI}+0,212_{Albedo}-0,001_{Precipitacão}+0,269_{Evapotranspiração}+0,013_{Temperatura}$	0,617	0,786	145	0,5177	0,7195
2000FC	$IGSD=1,096-0,272_{NDVI}+0,710_{Albedo}+0,159_{Evapotranspiração}+0,013_{Temperatura}$	0,657	0,811	106	0,6376	0,7985
2001FC	$IGSD=1,239-0,293_{NDVI}+1,127_{Albedo}+0,011_{Temperatura}+0,115_{Evapotranspiração}$	0,459	0,678	198	0,4682	0,6842
2003FS	$IGSD=1,470-0,409_{NDVI}+1,361_{Albedo}-0,338_{Indice\ de\ Aridez}+0,034_{Evapotranspiração}+0,003_{Temperatura}$	0,467	0,683	198	0,3575	0,5979
2004FS	$IGSD=1,619-0,522*_{NDVI}+0,051*_{Evapotranspiração}$	0,605	0,778	151	0,487	0,6978
2004FC	$IGSD=0,900-0,131_{NDVI}+0,993_{Albedo}+0,109_{Evapotranspiração}+0,020_{Temperatura}$	0,768	0,876	198	0,452	0,6723
2005FS	$IGSD=1,478-0,247_{NDVI}+1,057_{Albedo}+0,105_{\ Evapotranspiração}+0,004_{\ Temperatura}$	0,579	0,761	170	0,3398	0,5829
2005FC	$IGSD=1,211-0,388_{NDVI}+0,566_{\ Albedo}+0,239_{Evapotranspiração}+0,007_{Temperatura}$	0,63	0,794	162	0,3842	0,6198
2006FS	$IGSD=1,279-0,243_{NDVI}+0,915_{\ Albedo}+0,257_{Evapotranspiração}+0,009_{Temperatura}$	0,576	0,759	154	0,4382	0,662
2006FC	$IGSD=0,586+2,593_{\ Albedo}-0,255_{Indice\ de\ Aridez}+0,218_{Evapotranspiração}+0,021_{Temperatura}$	0,878	0,937	135	0,5788	0,7607
2007FC	$IGSD=1,293-0,398_{NDVI}+0,158_{TGSI}+2,168_{Albedo}+0,239_{Evapotranspiração}+0,003_{Temperatura}$	0,672	0,82	167	0,4664	0,6829
2011FC	$IGSD=0,824-0,135_{NDVI}+1,827_{Albedo}-0,00006862_{Precipitação}+0,025_{Evapotranspiração}+0,016_{Temperatura}$	0,615	0,784	144	0,4239	0,6511
2012FC	$IGSD=1,617-0,544_{NDVI}+0,255_{Albedo}-0,001_{Precipitação}+0,006_{Temperatura}$	0,74	0,86	151	0,5698	0,7548
2017FC	$IGSD=1,506-0,198_{NDVI}+2,204_{AlbedO}+0,168_{Evapotranspiração}$	0,676	0,822	136	0,4895	0,6996

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; 1997FC[1]: modelo de regressão múltipla selecionado; data: 23/09/1997.

APÊNDICE H – MODELOS DE REGRESSÃO LOGÍSTICA EM CANINDÉ

Período	Variável	βi	Exp(βi)	Treinamento			Validação			Amostras por Classes
				R^2 Nagelkerke	ROC	Taxa de Acerto (%)	R^2 Nagelkerke	ROC	Taxa de Acerto (%)	
1997FC[1]	NDVI	-14,546	4,82E-07	0,848	0,981	93,5	0,2321	0,91	78,5	D:130; ND:70
	Albedo	13,114	495835,749							
	Temperatura	0,345	1,411							
	Precipitação	-0,026	0,974							
	Evapotranspiração	6,104	447,644							
1998FC	NDVI	-46,87	4,41E-21	0,879	0,985	94	0,4035	0,645	60	D:110; ND:90
	Albedo	40,806	5,27E+17							
	Temperatura	0,6	1,822							
	Precipitação	-0,026	0,9743							
1999FC	NDVI	-32,828	5,53E-15	0,816	0,975	94,9	0,4289	0,475	8	D:12; ND:188
	Albedo	71,437	1,06E+31							
	Temperatura	0,536	1,7091							
2000FS	NDVI	-17,333	2,97E-08	0,653	0,914	88,4	0,524	0,333	71,71	D:183; ND:15
	Albedo	21,377	1922707143							
	Precipitação	-0,017	0,983							
	Evapotranspiração	12,073	175080,299							
	Temperatura	0,989	2,688							
2000FC	Temperatura	1,531	4,622	0,544	0,955	97,7	0,537	0,436	90,9	D:9; ND:189
	Evapotranspiração	10,748	46536,861							
	Albedo	56,198	2,55E+24							
	NDVI	-6,548	0,001							
2001FC	Evapotranspiração	14,855	2827772,904	0,636	0,984	99,1	0,0799	0,461	10,1	D:6; ND:192
	Albedo	163,862	1,46E+71							
	NDVI	-15,842	1,32E-07							
2003FS	Temperatura	0,836	2,307	0,744	0,906	97,7	0,4557	0,558	94,94	D:7; ND:191
	Evapotranspiração	23,077	10524797748							
	Índice de Aridez	-57,273	1,34E-25							

	Albedo	278,461	8,59E+120							
	TGSI	-85,88	5,04E-38							
2004FS	Temperatura	0,149	1,160	0,567	0,933	93	0,5866	0,841	86,86	D:177; ND:21
	Evapotranspiração	5,078	160,452							
	Albedo	182,034	1,14E+79							
	TGSI	-21,742	3,61E-10							
	NDVI	-24,013	3,73E-11							
2005FS	Temperatura	0,286	1,331	0,62	0,94	87,9	0,4438	0,61	39,89	D:194; ND:4
	Evapotranspiração	8,774	6463,976							
	Albedo	56,878	5,03E+24							
	NDVI	-24,079	3,49E-11							
2005FC	Temperatura	2,269	9,669	0,608	0,926	89,8	0,3996	0,524	69,19	D:39; ND:159
	Evapotranspiração	39,283	1,15E+17							
	Índice de Aridez	-8,996	0,00012							
	Albedo	146,946	6,57E+63							
	NDVI	-15,551	1,76E-07							
	TGSI	-45,163	2,43E-20							
2006FS	Índice de Aridez	-168,58	6,14E-74	0,789	0,99	97,7	0,607	0,394	89,89	D:187; ND:11
	Temperatura	0,602	1,825							
	Evapotranspiração	8,889	7251,763							
	Albedo	122,923	2,43E+53							
2007FC	Índice de Aridez	-37,836	3,70E-17	0,738	0,98	98,6	0,6256	0,682	93,43	D:8; ND:190
	Temperatura	3,356	28,67426412							
	Evapotranspiração	53,686	2,07E+23							
	Albedo	233,69	3,09E+101							
	NDVI	-24,61	2,05E-11							
2012FC	NDVI	-35,685	3,18E-16	0,65	0,935	88,8	0,3394	0,539	60,6	D:127; ND:71
	Precipitação	-0,024	0,976							
	Temperatura	0,558	1,747							
2017FC	NDVI	-30,153	8,03E-14	0,686	0,984	96,7	0,3638	0,507	84,84	D:27; ND:171
	Evapotranspiração	15,219	4069375,069							

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; ROC: (*receiver operator characteristic curve*); TA: taxa de acerto (%). 1997FC[1]: modelo selecionado; data: 23/09/1997.

APÊNDICE I – MODELOS DE REDES NEURAIS E SVM EM CANINDÉ

Período	Modelos			
	Rede Neural		SVM	
	R^2	RMSE	R^2	RMSE
1997FC	0,9348	0,0305	0,9255	0,0301
1998FC[2]	0,9125	0,0397	0,9702	0,0232
1999FC	0,9180	0,0280	0,9568	0,0193
2000FS	0,9181	0,0273	0,9462	0,0194
2000FC	0,9056	0,0339	0,9053	0,0372
2001FC	0,8165	0,0365	0,9145	0,0214
2003FS	0,8958	0,0192	0,9089	0,0169
2004FS	0,7677	0,0392	0,8649	0,0247
2004FC	0,9195	0,0227	0,9207	0,0204
2005FS	0,8386	0,0230	0,9349	0,0132
2005FC	0,8168	0,0299	0,8753	0,0286
2006FS	0,7016	0,0540	0,9333	0,0239
2006FC[1]	0,9474	0,0255	0,9034	0,0328
2007FC	0,8565	0,0312	0,9258	0,0237
2008FS	0,7770	0,0454	0,8929	0,0280
2008FC	0,7968	0,0359	0,9234	0,0234
2011FS	0,8132	0,0360	0,9057	0,0210
2011FC	0,9071	0,0248	0,9576	0,0148
2012FS	0,8184	0,0344	0,9238	0,0248
2012FC	0,8039	0,0398	0,8412	0,0305
2013FC	0,6894	0,0424	0,8899	0,0268
2014FC	0,8334	0,0331	0,8341	0,0268
2015FC	0,8115	0,0406	0,9402	0,0193
2016FC	0,8703	0,0280	0,9446	0,0206
2017FC	0,8911	0,0262	0,9376	0,0145
2018FC	0,8620	0,0366	0,8799	0,0254

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; 2006FC[1]: modelo de redes neurais selecionado; data: 14/07/2006; 1998FC[2]: modelo de SVM selecionado; data: 22/06/1998.

APÊNDICE J – MATRIZ DE CONFUSÃO MODELOS DE CANINDÉ

Modelo	Classificação	Referência			
		NA	P	F	Total
RLM	NA	10692	402	25	11119
	P	3324	3192	663	7179
	F	1178	378	451	2007
	Total	15194	3972	1139	20305
	Classificação	Referência			
		NA		BS	Total
RL	NA	18352		1980	20332
	BS	26624		13450	40074
	Total	44976		15430	60406
	Classificação	Referência			
		F	C	D	Total
Redes Neurais	F	6109	5778	353	12240
	C	781	3059	119	3959
	D	453	2406	1198	4057
	Total	7343	11243	1670	20256

Fonte: Elaboração própria; NA: não afetado; P: Potencial; F: Frágil; C: Crítico; D: Desertificado; BS: Baixa Suscetibilidade; MS: Moderada Suscetibilidade; AS: Alta Suscetibilidade; MAS: Muito Alta Suscetibilidade.

APÊNDICE L – ESTATÍSTICA DESCRITIVA IRAUÇUBA

Local	Período	Índice	Média	Intervalo interquartílico	Desvio Padrão	CV (%)
Irauçuba	1997FC	NDVI	0,284	0,2425 – 0,3227	0,069	24,31
		TGSI	0,232	0,2076 – 0,2570	0,073	31,37
		Albedo	0,137	0,0996 – 0,1568	0,06	43,59
		Temperatura	28,07	24,69 – 34,66	8,56	30,51
		Evapotranspiração	0,313	0 – 0,3217	0,21	67,04
		Precipitação	341,9	263,30 – 424,43	132,5	38,76
		Índice de Aridez	0,142	0,1094 – 0,1764	0,055	38,76
		IGSD	1,507	1,4501 – 1,6010	0,125	8,26
	1999FC	NDVI	0,387	0,2649 – 0,5106	0,196	50,71
		TGSI	0,239	0,1561 – 0,2997	0,126	52,9
		Albedo	0,156	0,0769 – 0,1628	0,137	87,88
		Temperatura	23,9	18,19 – 30,46	7,312	30,58
		Evapotranspiração	0,215	0 – 0,0104	0,17	79,23
		Precipitação	466,7	336,8 – 605,63	210	44,99
		Índice de Aridez	0,201	0,1448 – 0,2604	0,09	44,99
		IGSD	1,356	1,2916 – 1,4260	0,126	9,313
	2005FC	NDVI	0,313	0,2601 – 0,3643	0,092	29,49
		TGSI	0,203	0,1919 – 0,2323	0,053	25,92
		Albedo	0,1	0,0848 – 0,1198	0,033	33,21
		Temperatura	31,15	30,46 – 34,66	6,598	21,17
		Evapotranspiração	0,457	0,1341 – 0,5490	0,207	45,32
		Precipitação	287,7	174,60 – 425,74	166,6	57,89
		Índice de Aridez	0,243	0,1473 – 0,3592	0,141	57,89
		IGSD	1,521	1,4501 – 1,6010	0,093	6,117
	2012FS	NDVI	0,247	0,2051 – 0,2870	0,082	33,11
		TGSI	0,176	0,0927 - 0,2344	0,103	58,68
		Albedo	0,195	0,1164 – 0,2708	0,124	63,48
		Temperatura	30,22	24,59 - 36,74	8,05	26,66
		Evapotranspiração	0,39	0 – 0,2091	0,204	52,29
		IGSD	1,703	1,6403 – 1,7381	0,089	5,227
	2018FC	NDVI	0,37	0,2857 – 0,4272	0,169	45,5
		TGSI	0,133	0,0661 – 0,1879	0,071	53,29
		Albedo	0,158	0,0895 – 0,1624	0,143	90,57
		Temperatura	28,22	24,23 – 33,54	7,098	25,14
		Evapotranspiração	0,454	0 – 0,1431	0,241	53,19
		Precipitação	598,3	604 – 611,81	88,45	14,78
		Índice de Aridez	0,447	0,4514 – 0,4572	0,066	14,78
		IGSD	1,4	1,3135 – 1,4501	0,112	7,963

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; CV: Coeficiente de Variação; NDVI, TGSI, Albedo, Índice de Aridez e IGSD: Adimensional; Temperatura: C° (Celsius); Precipitação: mm (milímetros); Evapotranspiração: mm/h (milímetros por hora).

APÊNDICE M – MODELOS DE REGRESSÃO MÚLTIPLA EM IRAUÇUBA

Períodos	Modelos	Treinamento			Validação	
		R^2	R	Pontos Amostrados	R^2	R
1997FC[1]	$IGSD=1,588-0,807_{NDVI}+0,007_{Temperatura}+0,269_{Evapotranspiração}-0,974_{Indice\ de\ Aridez}$	0,801	0,895	69	0,6681	0,8174
1998FC	$IGSD=1,653-0,789_{NDVI}+0,009_{Temperatura}-0,001_{Precipitação}-0,076_{Evapotranspiração}$	0,794	0,891	92	0,6266	0,7916
1999FC	$IGSD=1,318-0,405_{NDVI}+0,007_{Temperatura}+0,114_{Evapotranspiração}$	0,765	0,875	92	0,5049	0,7105
2000FC	$IGSD=1,115-0,245_{NDVI}+0,921_{Albedo}+0,182_{Evapotranspiração}+0,008_{Temperatura}$	0,65	0,806	70	0,5274	0,7262
2004FS	$IGSD=1,517-0,415_{NDVI}+2,130_{Albedo}+0,137\ _{Evapotranspiração}+0,002\ _{Temperatura}-0,002_{Precipitação}$	0,619	0,787	79	0,56	0,7483
2004FC	$IGSD=1,309-0,280_{NDVI}+0,020_{TGSI}+1,671_{Albedo}+0,045_{Evapotranspiração}+0,002_{Temperatura}$	0,696	0,834	72	0,5424	0,7364
2005FS	$IGSD=1,569+0,256_{Albedo}+0,003_{Temperatura}$	0,652	0,808	85	0,4895	0,6996
2005FC	$IGSD=1,386-0,461_{NDVI}+2,128_{Albedo}-0,255_{Indice\ de\ Aridez}+0,246\ _{Evapotranspiração}+0,001_{Temperatura}$	0,783	0,885	66	0,6318	0,7949
2006FS	$IGSD=1,075+0,049_{TGSI}+1,290_{Albedo}+0,186\ _{Evapotranspiração}+0,013\ _{Temperatura}$	0,689	0,83	49	0,4246	0,6516
2006FC	$IGSD=1,306-0,327_{NDVI}+2,381_{Albedo}-0,091_{Indice\ de\ Aridez}+0,198_{Evapotranspiração}+0,001_{Temperatura}$	0,611	0,781	50	0,5761	0,759
2007FC	$IGSD=1,536-0,619_{NDVI}+2,040_{Albedo}+0,188\ _{Evapotranspiração}$	0,641	0,801	49	0,4735	0,6881
2011FS	$IGSD=1,827-0,637_{NDVI}+0,541_{Albedo}+0,150\ _{Evapotranspiração}-0,001_{Precipitação}$	0,684	0,827	66	0,5137	0,7167
2011FC	$IGSD=0,848-0,193_{NDVI}+0,146_{TGSI}+1,962_{Albedo}+0,013\ _{Evapotranspiração}+0,013\ _{Temperatura}$	0,854	0,924	52	0,4513	0,6718
2013FC	$IGSD=1,615-0,819_{NDVI}+0,293_{TGSI}+0,156\ _{Evapotranspiração}+0,008\ _{Temperatura}-0,001_{Precipitação}$	0,639	0,8	66	0,5178	0,7195
2014FC	$IGSD=1,350-0,490_{NDVI}+0,516_{Albedo}+0,178\ _{Evapotranspiração}+0,005\ _{Temperatura}$	0,692	0,832	60	0,4148	0,6441
2015FC	$IGSD=1,697-0,339_{NDVI}+0,904_{Albedo}+0,073\ _{Evapotranspiração}-0,001\ _{Precipitação}$	0,672	0,82	66	0,4859	0,6971
2016FC	$IGSD=1,399-0,425_{NDVI}-0,619_{TGSI}+0,399_{Albedo}+0,226\ _{Evapotranspiração}+0,011\ _{Temperatura}$	0,68	0,824	66	0,4705	0,6859
2018FC	$IGSD=1,515-0,447_{NDVI}-0,346_{Indice\ de\ Aridez}+0,115\ _{Evapotranspiração}+0,007\ _{Temperatura}$	0,636	0,797	47	0,4588	0,6773

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; 1997FC[1]: modelo de regressão múltipla selecionado; data: 23/09/1997.

APÊNDICE N – MODELOS DE REGRESSÃO LOGÍSTICA EM IRAUÇUBA

Período	Variável	βi	Exp(βi)	Treinamento			Validação			Amostras por classes
				R^2 Nagelkerke	ROC	TA (%)	R^2 Nagelkerke	ROC	TA (%)	
1997FC	Evapotranspiração	7,416	1662,37	0,813	0,969	90,6	0,2054	0,644	54,37	D:42; ND: 50
	Precipitação	-0,018	0,982							
	Temperatura	0,545	1,724							
	NDVI	-31,983	1,29E-14							
1998FC	Índice de Aridez	-82,483	1,51E-36	0,851	0,981	92,7	0,3554	0,931	88	D:56; ND: 36
	Temperatura	0,378	1,459							
	Albedo	44,448	2,01E+19							
	NDVI	-19	5,60E-09							
1999FC	Evapotranspiração	16,166	10490703,06	0,799	0,988	96,9	0,0168	0,615	45	D:10; ND: 82
	Temperatura	0,898	2,454							
	Albedo	24,291	35436209445							
2004FS	Temperatura	1,597	4,938	0,589	0,909	82,3	0,5766	0,543	71,77	D:86; ND: 6
	Evapotranspiração	24,352	37665108542							
	Albedo	113,429	1,83E+49							
	NDVI	-21,986	2,83E-10							
2004FC	Albedo	225,2	6,36E+97	0,862	0,993	96,9	0,1937	0,717	58,88	D:14; ND: 78
	NDVI	-42,888	2,37E-19							
2005FS	Temperatura	0,075	1,077	0,603	0,99	99	0,3849	0,628	95,65	D:88; ND:2
2005FC[1]	Temperatura	0,86	2,363	0,72	0,94	83,3	0,4638	0,664	66,29	D:43; ND: 47
	Evapotranspiração	15,893	7984398,436							
	Índice de Aridez	-15,173	2,57E-07							
	Albedo	107,572	5,22E+46							
	NDVI	-13,986	8,43E-07							
2006FS	Temperatura	0,375	1,454	0,548	0,938	90,6	0,6763	0,968	92,22	D:86; ND: 4
	Evapotranspiração	2,688	14,702							

	Albedo	31,761	6,22E+13							
2007FC	Índice de Aridez	-307,72	2,29E-134	0,757	0,958	86,5	0,2696	0,949	67,77	D:32; ND:58
	Temperatura	0,692	1,997							
	Evapotranspiração	11,125	67846,291							
	Albedo	77,904	6,81E+33							
2011FS	Precipitação	-0,018	0,982	0,7	0,932	85,4	0,1051	0,888	51,68	D:44; ND: 46
	Evapotranspiração	9,221	10107,166							
	NDVI	-43,951	8,17E-20							
2013FC	Precipitação	-0,066	0,936	0,805	0,971	89,6	0,0298	0,694	56	D:28; ND: 38
	Temperatura	0,643	1,902							
	Evapotranspiração	15,364	4704358,606							
	NDVI	-42,57	3,25E-19							
2014FC	Evapotranspiração	20,751	1028122335	0,63	0,935	90,6	0,0808	0,787	34,84	D:7; ND: 59
	Índice de Aridez	-70,105	3,58E-31							
	Albedo	108,088	8,75E+46							
2016FC	Temperatura	1,15	3,158	0,813	0,97	94,8	0,1153	0,435	63,63	D:45; ND: 21
	Evapotranspiração	8,979	7934,693							
	Albedo	-44,32	5,65E-20							
	NDVI	-32,626	6,77E-15							
	TGSI	-38,802	1,41E-17							
2018FC	Temperatura	0,31	1,363	0,635	0,923	84,4	0,3063	0,578	33,33	D:19; ND:47

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; ROC: (*receiver operator characteristic curve*); TA: taxa de acerto (%); 2005FC[1]: modelo selecionado; data: 13/09/2005.

APÊNDICE O – MODELOS DE REDES NEURAIS E SVM EM IRAUÇUBA

Período	Modelos			
	Rede Neural		SVM	
	R^2	RMSE	R^2	RMSE
1997FC	0,9230	0,0380	0,9703	0,0154
1998FC	0,9282	0,0375	0,9581	0,0280
1999FC[1]	0,9602	0,0251	0,9606	0,0221
2000FS	0,8517	0,0257	0,8762	0,0221
2000FC	0,8976	0,0304	0,9468	0,0218
2001FC	0,9178	0,0184	0,9629	0,0132
2003FS	0,8698	0,0234	0,9143	0,0116
2004FS	0,9104	0,0336	0,9114	0,0200
2004FC	0,9168	0,0262	0,9355	0,0253
2005FS	0,8406	0,0308	0,9494	0,0167
2005FC	0,9537	0,0157	0,9798	0,0148
2006FS	0,9017	0,0300	0,9719	0,0127
2006FC	0,8771	0,0320	0,9227	0,0238
2007FC	0,8946	0,0311	0,9221	0,0239
2008FS	0,8464	0,0376	0,8813	0,0232
2008FC	0,6755	0,0407	0,9417	0,0132
2008FC	0,6755	0,0407	0,9417	0,0132
2011FS	0,8681	0,0222	0,9148	0,0194
2011FC	0,8808	0,0318	0,9320	0,0211
2012FS[2]	0,8618	0,0369	0,9832	0,0122
2012FC	0,8358	0,0384	0,9113	0,0163
2013FC	0,8849	0,0397	0,9263	0,0310
2014FC	0,8302	0,0215	0,8872	0,0195
2015FC	0,8871	0,0306	0,9499	0,0167
2016FC	0,7019	0,0528	0,8319	0,0250
2017FC	0,8173	0,0299	0,8456	0,0231
2018FC	0,7927	0,0466	0,9444	0,0250

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; 1999FC[1]: modelo de redes neurais selecionado; data: 15/10/1999; 2012FS[2]: modelo de SVM selecionado*;* data: 11/11/2012.

APÊNDICE P – MATRIZ DE CONFUSÃO MODELOS DE IRAUÇUBA

Modelo	Classificação	Referência				
		NA	**P**	**F**	**C**	**Total**
RLM	**NA**	34469	898	53	94	35514
	P	1359	3057	539	597	5552
	F	1710	11954	7210	5025	25899
	C	384	834	335	6926	8479
	Total	37922	16743	8137	12642	75444

	Classificação	Referência				
		NA	**BS**	**MS**	**AS**	**Total**
RL	**NA**	3021	2170	467	110	5768
	BS	1441	28152	2253	265	32111
	MS	129	2220	9742	3235	15326
	AS	22	602	9526	10584	20734
	Total	4613	33144	21988	14194	73939

	Classificação	Referência					
		NA	**P**	**F**	**C**	**D**	**Total**
Redes Neurais	**NA**	18183	2550	90	162	30	21015
	P	4521	19936	1645	711	134	26947
	F	184	3776	3473	1058	822	9313
	C	596	8864	7335	8120	2101	27016
	D	42	1752	2901	2423	3468	10586
	Total	23526	36878	15444	12474	6555	94877

	Classificação	Referência					
		NA	**P**	**F**	**C**	**D**	**Total**
SVM	**NA**	12357	5716	1356	64	740	20233
	P	1880	4161	2017	135	311	8504
	F	970	4255	37635	755	1404	45019
	C	277	881	5324	5593	1626	13701
	D	215	1452	3643	856	2444	8610
	Total	15699	16465	49975	7403	6525	96067

Fonte: Elaboração própria; NA: não afetado; P: Potencial; F: Frágil; C: Crítico; D: Desertificado; BS: Baixa Suscetibilidade; MS: Moderada Suscetibilidade; AS: Alta Suscetibilidade; MAS: Muito Alta Suscetibilidade.

APÊNDICE Q – ESTATÍSTICA DESCRITIVA SANTA QUITÉRIA

Local	Período	Índice	Média	Intervalo interquartílico	Desvio Padrão	CV (%)
Santa Quitéria	2011FS	NDVI	0,3876	0,3036 - 0,4657	0,1071	27,62
		TGSI	0,2191	0,1968 -0,2383	0,0337	15,36
		Albedo	0,1071	0,0940 – 0,1178	0,0205	19,18
		Temperatura	34,3	33,13 – 36,08	3,7119	10,82
		Evapotranspiração	0,2599	0,0678 – 0,3162	0,1626	62,56
		Precipitação	52,65	5,3557 – 87,42	62,27	118,28
		Índice de Aridez	0,0492	0,0052 – 0,0857	0,0606	122,98
		IGSD	1,6008	1,4858 – 1,6682	0,1103	6,8885
	2016FC	NDVI	0,3601	0,3112 – 0,4018	0,1054	29,29
		TGSI	0,2317	0,2110 - 0,2483	0,0975	42,1
		Albedo	0,1151	0,0880 – 0,1175	0,0791	68,73
		Temperatura	32,95	31,23 – 35,67	4,5272	13,73
		Evapotranspiração	0,3957	0,2045 – 0,4823	0,1898	47,95
		Precipitação	522,75	510,04 – 603,35	142,46	27,25
		Índice de Aridez	0,3805	0,3712 – 0,4391	0,1037	27,25
		IGSD	1,4462	1,3686 - 1,5110	0,0885	6,1182
	2018FC	NDVI	0,3388	0,2671 – 0,4268	0,1584	46,76
		TGSI	0,1282	0,0477 – 0,2002	0,0903	70,45
		Albedo	0,1839	0,0996 – 0,1690	0,1788	97,21
		Temperatura	25,61	20,75 – 32,77	8,501	33,19
		Evapotranspiração	0,4117	-	0,2342	56,15
		Precipitação	660,55	642,81 – 724,58	142,85	21,62
		Índice de Aridez	0,4937	0,4804 – 0,5415	0,1067	21,62
		IGSD	1,3892	1,2915 – 1,4501	0,1113	8,0181

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; CV: Coeficiente de Variação; NDVI, TGSI, Albedo, Índice de Aridez e IGSD: Adimensional; Temperatura :C°(Celsius); Precipitação mm (milímetros); Evapotranspiração: mm/h (milímetros por hora).

APÊNDICE R – MODELOS DE REGRESSÃO MÚLTIPLA EM SANTA QUITÉRIA

Períodos	Modelos	Treinamento			Validação	
		R^2	R	Pontos Amostrados	R^2	R
1999FC	$IGSD=0,970-0,076_{NDVI}+0,751_{Albedo}+0,016_{Temperatura}-0,364_{Índice\ de\ Aridez}+0,131_{Evapotranspiração}$	0,663	0,814	279	0,4949	0,7035
2000FS	$IGSD=1,201-0,353_{NDVI}+1,995_{Albedo}+0,190_{Evapotranspiração}+0,010_{Temperatura}$	0,646	0,804	231	0,5388	0,734
2000FC	$IGSD=1,228-0,308_{NDVI}+0,053_{TGSI}+0,571_{Albedo}+0,184_{Evapotranspiração}+0,009_{Temperatura}$	0,734	0,857	208	0,4494	0,6704
2001FC	$IGSD=1,118-0,290_{NDVI}+0,004_{TGSI}+0,759_{Albedo}+0,010_{Temperatura}+0,220_{Evapotranspiração}$	0,787	0,887	192	0,5314	0,729
2004FS	$IGSD=1,370-0,392_{NDVI}+2,579_{Albedo}+0,198_{Evapotranspiração}+0,004_{temperatura}$	0,612	0,782	196	0,512	0,7155
2004FC	$IGSD=1,380-0,422_{NDVI}+0,008_{TGSI}+1,599_{Albedo}-0,045_{Indice\ de\ Aridez}+0,132_{Evapotranspiração}+0,001_{Temperatura}$	0,767	0,876	216	0,5444	0,7378
2005FS	$IGSD=1,393-0,148_{NDVI}+1,638_{Albedo}+0,174_{Evapotranspiração}+0,004_{Temperatura}$	0,609	0,78	257	0,4685	0,6845
2005FC	$IGSD=1,371-0,423_{NDVI}-0,114_{TGSI}+1,480_{Albedo}+0,228_{Evapotranspiração}+0,002_{Temperatura}$	0,782	0,884	197	0,5239	0,7238
2006FC	$IGSD=1,386-0,275_{NDVI}+0,012_{TGSI}+0,734_{Albedo}-0,00004587_{Precipitacão}+0,197_{Evapotranspiração}+0,001_{Temperatura}$	0,642	0,801	229	0,507	0,712
2007FC	$IGSD=1,315-0,591_{NDVI}+1,310_{Albedo}+0,208_{Evapotranspiração}+0,005_{Temperatura}-0,00006695_{Precipitacão}$	0,65	0,806	224	0,4601	0,6783
2011FS	$IGSD=1,602-0,627_{NDVI}+1,217_{Albedo}+0,149_{Evapotranspiração}+0,003_{Temperatura}-0,001_{Precipitacão}$	0,816	0,903	272	0,5223	0,7227
2012FC	$IGSD=1,507-0,582_{NDVI}+0,220_{Albedo}-0,726_{Indice\ de\ Aridez}+0,140_{Evapotranspiração}+0,010_{Temperatura}$	0,651	0,807	219	0,5763	0,7591
2013FC	$IGSD=1,581-0,638_{NDVI}+0,182_{TGSI}+0,415_{Albedo}+0,183_{Evapotranspiração}+0,005_{Temperatura}-0,001_{Precipitacão}$	0,72	0,848	232	0,5283	0,7268
2014FC	$IGSD=1,572-0,566_{NDVI}+0,334_{TGSI}+0,354_{Albedo}+0,182_{Evapotranspiração}+0,004_{Temperatura}$	0,691	0,831	250	0,4883	0,6988
2018FC[1]	$IGSD=1,611-0,490_{NDVI}+0,348_{TGSI}-0,377_{Indice\ de\ Aridez}+0,124_{Evapotranspiração}+0,003_{Temperatura}$	0,65	0,806	167	0,6369	0,798

Fonte: Elaboração Própria**;** FS: Final do Período Seco; FC: Final do Período Chuvoso; 2018FC[1]: modelo selecionado; data: 06/07/2018.

APÊNDICE S – MODELOS DE LOGÍSTICA EM SANTA QUITÉRIA

Período	Variável	βi	Exp(βi)	Treinamento			Validação/Teste			Amostras por classes
				R^2 Nagelkerke	ROC	TA (%)	R^2 Nagelkerke	ROC	TA (%)	
1999FC	Índice de Aridez	-10,35	3,17E-05	0,732	0,972	95,5	0,2371	0,41	85,55	D:38; ND: 239
	Albedo	-20,85	8,77E-10							
	NDVI	-62,16	1,00E-27							
2000FS	Evapotranspiração	0,16	1,173	0,638	0,974	95,8	0,1911	0,561	51,44	D:124; ND: 153
	Albedo	79,847	4,75E+34							
	NDVI	-21,22	6,08E-10							
2000FC	Temperatura	2,209	9,106	0,576	0,956	93,4	0,243	0,59	91,69	D:9; ND: 268
	Evapotranspiração	19,5	294267566							
	Albedo	85,882	1,99E+37							
	NDVI	-16,28	8,46E-08							
2001FC	Índice de Aridez	-17,77	1,90E-08	0,627	0,971	96,2	0,2361	0,55	78,96	D:38; ND: 233
	Evapotranspiração	11,971	158102,684							
	Temperatura	1,944	6,986							
	Albedo	129,06	1,12E+56							
2004FS	Temperatura	1,135	3,111	0,536	0,891	80,2	0,3511	0,485	57,19	D:260; ND:11
	Evapotranspiração	18,865	155942826,3							
	Albedo	100,5	4,41E+43							
	NDVI	-25	1,39E-11							
2004FC	Temperatura	0,985	2,677	0,509	0,908	87,8	0,2489	0,585	77,85	D:42; ND:229
	Evapotranspiração	18,69	130907300,4							
	Albedo	105,27	5,20E+45							
	NDVI	-14,32	5,99E-07							
2005FC	Temperatura	3,378	29,3127	0,75	0,901	95,5	0,2192	0,487	50	D:151; ND:120
	Evapotranspiração	59,983	1,12E+26							
	Albedo	233,1	1,72E+101							
	NDVI	-48,52	8,44E-22							

2007FC	Índice de Aridez	-20,3	1,51E-09	0,575	0,944	95,8	0,3458	0,725	93,7	D:19; ND:252
	Temperatura	1,352	3,865							
	Evapotranspiração	21,139	1515482944							
	Albedo	86,436	3,46E+37							
	NDVI	-13,13	1,97E-06							
2011FS	Índice de Aridez	-25,49	8,50E-12	0,831	0,98	93,1	0,3268	0,612	39,4	D:202; ND:69
	Evapotranspiração	7,57	1939,140							
	Albedo	74,256	1,77E+32							
	NDVI	-32,49	7,75E-15							
2012FC	Temperatura	0,285	1,3298	0,688	0,94	88,9	0,0612	0,793	29,88	D:197; ND:74
	Índice de Aridez	-42,79	2,59E-19							
	NDVI	-25,61	7,48E-12							
2013FC	Índice de Aridez	-27,33	1,34E-12	0,542	0,878	79,9	0,2236	0,74	67,15	D:111; ND:160
	Temperatura	0,506	1,658							
	Evapotranspiração	6,802	899,644							
	NDVI	-12,88	2,53E-06							
	Albedo	14,935	3063289,817							
2014FC	Temperatura	1,022	2,778	0,596	0,92	92,7	0,0196	0,504	25,46	D:28; ND:243
	Evapotranspiração	12,559	284645,549							
	TGSI	13,531	752382,411							
	NDVI	-35,02	6,12E-16							
2018FC[1]	Temperatura	0,468	1,596	0,841	0,981	93,4	0,1206	0,579	57,77	D:112; ND:159
	Evapotranspiração	6,143	465,447							
	TGSI	10,341	30976,991							
	NDVI	-15,22	2,45E-07							

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; ROC: (*receiver operator characteristic curve*); TA: taxa de acerto (%); 2018FC[1]: modelo selecionado; data: 06/07/2018.

APÊNDICE T – MODELOS DE REDES NEURAIS E SVM EM SANTA QUITÉRIA

Período	Modelos			
	Rede Neural		SVM	
	R^2	RMSE	R^2	RMSE
1997FC	0,7182	0,0283	0,8699	0,0163
1998FC	0,8844	0,0291	0,8240	0,0266
1999FC	0,8994	0,0344	0,8295	0,0386
2000FS	0,8746	0,0316	0,8619	0,0332
2000FC	0,8193	0,0565	0,8894	0,0354
2001FC	0,9052	0,0298	0,8998	0,0290
2001FC	0,9052	0,0298	0,8998	0,0290
2003FS	0,7193	0,0355	0,8274	0,0231
2004FS	0,7471	0,0403	0,8605	0,0325
2004FC	0,9230	0,0284	0,9307	0,0256
2005FS	0,7668	0,0347	0,8608	0,0225
2005FC	0,8843	0,0358	0,9335	0,0222
2006FS	0,8456	0,0294	0,8494	0,0273
2006FC	0,8349	0,0326	0,8272	0,0316
2007FC	0,8189	0,0356	0,9187	0,0196
2008FS	0,6590	0,0460	0,8196	0,0275
2008FC	0,8319	0,0324	0,8335	0,033
2011FS[1]	0,9299	0,0292	0,5404	0,0586
2011FC	0,8483	0,0309	0,8052	0,0329
2012FS	0,8272	0,0327	0,8210	0,0240
2012FC	0,7853	0,0278	0,6647	0,0387
2013FC	0,8517	0,0352	0,8765	0,0267
2014FC	0,7115	0,0418	0,7484	0,0229
2015FC	0,7484	0,0356	0,8987	0,0226
2016FC[2]	0,8296	0,0402	0,9348	0,0218
2017FC	0,6705	0,0463	0,8232	0,0264
2018FC	0,8228	0,0555	0,9150	0,0317

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; 2011FS[1]: modelo de redes neurais selecionado; data: 18/12/2011; 2016FC[2]: modelo de SVM selecionado; data: 17/08/2016.

APÊNDICE U – MATRIZ DE CONFUSÃO MODELOS DE SANTA QUITÉRIA

Modelo	Classificação	Referência					
		NA	P	F	C	D	Total
RLM	NA	12357	5716	1356	64	740	20233
	P	1880	4161	2017	135	311	8504
	F	970	4255	37635	755	1404	45019
	C	277	881	5324	5593	1626	13701
	D	215	1452	3643	856	2444	8610
	Total	15699	16465	49975	7403	6525	96067

RL	Classificação	Referência					
		NA	BS	MS	AS	MAS	Total
	NA	37380	8196	96	250	39	45961
	BS	6355	15997	1018	358	241	23969
	MS	1866	15859	14873	2900	798	36296
	AS	415	2879	2310	1946	679	8229
	MAS	162	2319	1985	1194	1836	7496
	Total	46178	45250	20282	6648	3593	121951

Redes Neurais	Classificação	Referência				
		NA	F	C	D	Total
	NA	63450	8735	677	95	72957
	F	5159	13144	3347	741	22391
	C	496	24004	23741	6019	54260
	D	307	6963	4307	2476	14053
	Total	69412	52846	32072	9331	163661

SVM	Classificação	Referência				
		NA	F	C	D	Total
	NA	46753	598	596	270	48217
	F	369	9991	6965	4679	22004
	C	736	3989	7731	3406	15862
	D	201	824	874	2557	4456
	Total	48059	15402	16166	10912	90539

Fonte: Elaboração própria; NA: não afetado; P: Potencial; F: Frágil; C: Crítico; D: Desertificado; BS: Baixa Suscetibilidade; MS: Moderada Suscetibilidade; AS: Alta Suscetibilidade; MAS: Muito Alta Suscetibilidade.

APÊNDICE V – ESTATÍSTICA DESCRITIVA ICN

Local	Período	Índice	Média	Intervalo Interquartílico	Desvio Padrão	CV (%)
Santa Quitéria	1999FC	NDVI	0,425	0,2973 – 0,5572	0,197	46,42%
		TGSI	0,2481	0,2248 – 0,2873	0,099	39,87
		Albedo	0,1304	0,0805 – 0,1358	0,104	79,76
		Temperatura	28,8	26,57 – 33,83	6,431	22,32
		Evapotranspiração	0,3008	0 - 0,2181	0,174	57,98
		Precipitação	639,39	510,56 – 799,03	232,3	36,34
		Índice de Aridez	0,275	0,2195 – 0,3436	0,1	36,34
		IGSD	1,388	1,2915 – 1,4501	0,116	8,3641
	2000FS	NDVI	0,2907	0,2482 – 0,3519	0,107	36,66
		TGSI	0,1907	0,1612 – 0,2341	0,086	45,17
		Albedo	0,1365	0,1002 – 0,1378	0,084	61,19
		Temperatura	30,95	29,61 – 34,66	5,876	18,98
		Evapotranspiração	0,2876	0 – 0,2812	0,204	70,74
		Precipitação	41,47	28,30 - 48,60	24,29	58,57
		Índice de Aridez	0,0316	0,0215 – 0,0370	0,019	58,57
		IGSD	1,6676	1,5743 – 1,7381	0,117	6,9876
	2001FC	NDVI	0,4189	0,3440 – 0,5054	0,151	35,97
		TGSI	0,2455	0,2279 – 0,2891	0,088	35,68
		Albedo	0,0644	0,0496 – 0,0680	0,039	61,33
		Temperatura	28,33	27,01 – 30,89	4,142	14,61
		Evapotranspiração	0,4822	0 – 0,4648	0,327	67,78
		Precipitação	433,33	307,94 – 547,91	168,2	38,81
		Índice de Aridez	0,4352	0,3093 – 0,5503	0,169	38,81
		IGSD	1,3229	1,2915 – 1,4259	0,254	19,18
	2018FC	NDVI	0,3613	0,3018 – 0,4288	0,15	41,45
		TGSI	0,1486	0,0909 – 0,2048	0,081	54,77
		Albedo	0,1512	0,0937 - 0,1398	0,14	92,64
		Temperatura	28,69	25,16 - 34,34	7,601	26,48
		Evapotranspiração	0,4062	0 – 0,2632	0,242	59,48
		Precipitação	648,24	607,37 – 710,70	137,5	21,21
		Índice de Aridez	0,4845	0,4539 – 0,5312	0,103	21,21
		IGSD	1,4028	1,3134 – 1,4501	0,108	7,667

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; CV: Coeficiente de Variação; NDVI, TGSI, Albedo, Índice de Aridez e IGSD: Adimensional; Temperatura :C°(Celsius); Precipitação mm (milímetros); Evapotranspiração: mm/h (milímetros por hora).

APÊNDICE X – MODELOS DE REGRESSÃO MÚLTIPLA EM ICN

Períodos	Modelos	Treinamento			Validação	
		R^2	R	Pontos Amostrados	R^2	R
1998FC	$IGSD=1,447-0,613_{NDVI}+0,100_{TGSI}+0,143_{Albedo}+0,012_{Temperatura}-1,328_{Índice\ de\ Aridez}$	0,663	0,814	556	0,3974	0,6304
1999FC[1]	$IGSD=1,177-0,281_{NDVI}+0,259_{Albedo}+0,010_{Temperatura}+0,054_{Evapotranspiração}$	0,755	0,869	454	0,5095	0,7138
2000FS	$IGSD=1,213-0,416_{NDVI}+2,034_{Albedo}+0,195_{Evapotranspiração}+0,010_{Temperatura}$	0,646	0,803	615	0,4066	0,6377
2000FC	$IGSD=1,199-0,279_{NDVI}+0,034_{TGSI}+0,607_{Albedo}+0,174_{Evapotranspiração}+0,008_{Temperatura}-0,00009458_{Precipitação}$	0,664	0,815	527	0,3542	0,5951
2001FC	$IGSD=1,707-0,337_{NDVI}+0,007_{TGSI}+0,002_{Evapotranspiração}+0,032_{Índice\ de\ Aridez}$	0,787	0,887	506	0,0961	0,3101
2004FS	$IGSD=1,473-0,495_{NDVI}+2,529_{Albedo}+0,152_{Evapotranspiração}+0,002_{Temperatura}$	0,644	0,803	508	0,3924	0,6264
2004FC	$IGSD=1,366-0,364_{NDVI}+0,001_{TGSI}+1,623_{Albedo}-0,00006078_{Precipitação}+0,126_{Evapotranspiração}+0,001_{Temperatura}$	0,729	0,854	550	0,373	0,6107
2005FC	$IGSD=1,239-0,339_{NDVI}+0,795_{Albedo}-0,212_{Índice\ de\ Aridez}+0,233_{Evapotranspiração}+0,008_{Temperatura}$	0,698	0,835	531	0,342	0,5848
2006FC	$IGSD=1,310-0,290_{NDVI}+1,813_{Albedo}-0,00006167_{Precipitação}+0,217_{Evapotranspiração}+0,001_{Temperatura}$	0,712	0,844	519	0,3585	0,5988
2012FC	$IGSD=1,541-0,504_{NDVI}+0,345_{Albedo}-0,774_{Índice\ de\ Aridez}+0,091_{Evapotranspiração}+0,007_{Temperatura}$	0,677	0,823	518	0,3416	0,5844
2013FC	$IGSD=1,546-0,647_{NDVI}+0,171_{TGSI}+0,134_{Albedo}+0,153_{Evapotranspiração}+0,006_{Temperatura}$	0,619	0,787	511	0,3788	0,6155
2014FC	$IGSD=1,522-0,473_{NDVI}+0,089_{TGSI}+0,367_{Albedo}-0,00007387_{Precipitação}+0,129_{Evapotranspiração}+0,001_{Temperatura}$	0,605	0,778	466	0,35	0,5916
2018FC	$IGSD=1,530-0,431_{NDVI}+0,233_{TGSI}+0,107_{Evapotranspiração}+0,005_{Temperatura}$	0,61	0,781	511	0,2462	0,4962

Fonte: Elaboração Própria**;** FS: Final do Período Seco; FC: Final do Período Chuvoso; 1999FC[1]: modelo selecionado; datas: (16/06/1999 – Miraíma); (15/10/1999 – Canindé e Irauçuba); (02/07/1999 – Santa Quitéria).

APÊNDICE Z – MODELOS DE REGRESSÃO LOGÍSTICA EM ICN

Período	Variável	βi	Exp (βi)	Treinamento			Validação			Amostras por Classe
				R^2 Nagelkerke	ROC	TA (%)	R^2 Nagelkerke	ROC	TA (%)	
1998FC	Temperatura	0,707	2,028	0,829	0,985	96	0,1279	0,509	70,14	D:500; ND:113
	Albedo	72,774	4,03E+31							
	NDVI	-45,35	0							
1999FC	Evapotranspiração	3,051	21,136	0,693	0,96	93,4	0,2301	0,546	68,3	D:117; ND:495
	Temperatura	0,509	1,664							
	Albedo	-11,13	0							
	NDVI	-49,29	0							
2001FC[1]	Precipitação	-0,011	0,989	0,877	0,976	95,5	0,1442	0,973	93,93	D:328 ND:281
	Evapotranspiração	0,053	1,054							
	Albedo	12,223	203.414,29							
	TGSI	1,355	3,877							
2004FS	Temperatura	0,839	2,314	0,607	0,918	85,1	0,1488	0,472	60,49	D:214 ND:395
	Evapotranspiração	15,541	5.615.268,71							
	Albedo	83,451	1,75E+36							
	NDVI	-26,73	0							
2004FC	Evapotranspiração	11,451	93.995,29	0,584	0,989	98,3	0,321	0,586	42,13	D:12; ND:597
	Albedo	43,829	1,08E+19							
	NDVI	-12,96	0							
2005FC	Temperatura	0,61	1,84	0,59	0,903	80	0,1916	0,485	48,85	D:278; ND:532
	Evapotranspiração	16,024	9.101.956,97							
	Albedo	37,698	2,36E+16							
	NDVI	-28,09	0							
2012FC	Temperatura	0,175	1,191	0,59	0,908	87,2	32,29	0,1616	0,484	D:454; ND:156
	Índice de aridez	-33,75	0							
	NDVI	-15,71	0							
2013FC	Temperatura	0,467	1,595	0,57	0,906	85,8	57,54	0,194	0,527	D:404; ND:206
	Evapotranspiração	5,587	266,934							

	TGSI	13,242	563543,6096							
	NDVI	-29,68	0							
2018FC	Temperatura	0,141	1,151	0,447	0,91	91,3	90,16	0,1196	0,679	D:62; ND:547
	Evapotranspiração	5,127	168,511							
	Índice de Aridez	-10,149	0							
	NDVI	-12,555	0							

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; ROC: (*receiver operator characteristic curve*); TA: taxa de acerto (%); 2001FC[1]: modelo selecionado; datas: (23/07/2011 - Miraíma); (01/08/2011 - Canindé e Irauçuba); (07/07/2001 – Santa Quitéria).

APÊNDICE AA – MODELOS DE REDES NEURAIS E SVM EM ICN

Período	Modelos			
	Rede Neural		SVM	
	R^2	RMSE	R^2	RMSE
1997FC	0,9552	0,0238	0,9398	0,0251
1998FC	0,8639	0,0496	0,9013	0,0373
1999FC	0,8822	0,0345	0,9008	0,0329
2000FS[1]	0,9649	0,0167	0,9158	0,0266
2000FC	0,9217	0,0324	0,9124	0,0303
2001FC	0,9386	0,0430	0,9406	0,04009
2003FS	0,7475	0,0292	0,7879	0,0206
2004FS	0,8550	0,0355	0,8530	0,0317
2004FC	0,9217	0,0188	0,8906	0,0299
2005FS	0,8678	0,0214	0,8270	0,0222
2005FC	0,8911	0,0311	0,9029	0,0282
2006FS	0,887	0,0262	0,9041	0,0242
2006FC	0,8925	0,0315	0,8876	0,0305
2007FC	0,8429	0,0317	0,9045	0,0283
2008FS	0,8057	0,0331	0,8204	0,0330
2008FC	0,7418	0,0395	0,8262	0,0295
2011FS	0,8790	0,0334	0,6132	0,0465
2011FC	0,8994	0,0277	0,8362	0,0330
2012FS	0,9030	0,0221	0,8623	0,0261
2012FC	0,7952	0,0372	0,8486	0,0315
2013FC	0,8932	0,0293	0,9156	0,0275
2014FC	0,8665	0,0217	0,8671	0,0198
2015FC	0,8245	0,0299	0,8941	0,0241
2016FC[2]	0,8407	0,0304	0,8862	0,0257
2017FC	0,8595	0,0256	0,7774	0,0301
2018FC	0,8798	0,0380	0,8085	0,0422

Fonte: Elaboração Própria; FS: Final do Período Seco; FC: Final do Período Chuvoso; 2000FS[1]: modelo de redes neurais selecionado; datas: (25/11/2000 – Miraíma); (17/10/2000 – Canindé e Irauçuba); (22/09/2000 – Santa Quitéria); 2016FC[2]: modelo de SVM selecionado; datas: (01/08/2016 – Miraíma); (25/07/2016 – Canindé e Irauçuba); (17/08/2016).

APÊNDICE AB – MATRIZ DE CONFUSÃO MODELOS ICN

Modelo	Classificação	Referência					
		NA	P	F	C	D	Total
RLM	NA	29435	574	978	80	41	31108
	P	488	78314	6288	6320	1106	92516
	F	1064	2690	14043	1291	995	20083
	C	6	1148	1598	9602	1572	13926
	D	3	2597	4192	21245	9909	37946
	Total	30996	85323	27099	38538	13623	195579

	Classificação	Referência				
		NA	BS	MS	AS	Total
RL	NA	71535	11909	2415	330	86189
	BS	2745	5164	1795	349	10053
	MS	3364	31012	56479	7214	98069
	AS	677	9664	10739	21722	42802
	Total	78321	57749	71428	29615	237113

	Classificação	Referência					
		NA	P	F	C	D	Total
Redes Neurais	NA	31517	2998	1785	487	199	36986
	P	2808	37354	8659	5644	1901	56366
	F	122	1414	4287	2046	701	8570
	C	35	1487	3653	4538	1231	10944
	D	546	18495	29847	27151	12855	88894
	Total	35028	61748	48231	39866	16887	201760

	Classificação	Referência					
		NA	P	F	C	D	Total
SVM	NA	34796	5425	276	88	0	40585
	P	1328	28577	2705	1389	242	34241
	F	197	6449	13614	6673	1988	28921
	C	8	558	2133	1940	514	5153
	D	10	7175	15061	9657	11736	43639
	Total	36339	48184	33789	19747	14480	152539

Fonte: Elaboração própria; NA: não afetado; P: Potencial; F: Frágil; C: Crítico; D: Desertificado; BS: Baixa Suscetibilidade; MS: Moderada Suscetibilidade; AS: Alta Suscetibilidade; MAS: Muito Alta Suscetibilidade.