

**UNIVERSIDADE FEDERAL DO PAMPA**

**JOSE LUIS JUAREZ RUELAS**

**MODELAGEM DO PARÂMETRO DE IRRIGAÇÃO: UM ESTUDO DE CASO PARA  
O CAPIM SUDÃO BRS ESTRIBO**

**Bagé  
2018**

**JOSE LUIS JUAREZ RUELAS**

**MODELAGEM DO PARÂMETRO DE IRRIGAÇÃO: UM ESTUDO DE CASO PARA  
O CAPIM SUDÃO BRS ESTRIBO**

Dissertação apresentada ao Programa de Pós-graduação em Computação Aplicada da Universidade Federal do Pampa, como parte dos requisitos para a obtenção do título de Mestre em Computação Aplicada.

Orientador: Dr. Milton Roberto Heinen

Coorientador: Dr. Gustavo Trentin

**Bagé  
2018**

Ficha catalográfica elaborada automaticamente com os dados fornecidos  
pelo(a) autor(a) através do Módulo de Biblioteca do  
Sistema GURI (Gestão Unificada de Recursos Institucionais) .

R921m Ruelas, Jose Luis Juarez

Modelagem do parâmetro de irrigação: um estudo de  
caso para o capim sudão brs estribo / Jose Luis  
Juarez Ruelas.

82 p.

Dissertação (Mestrado)-- Universidade Federal do  
Pampa, MESTRADO EM COMPUTAÇÃO APLICADA, 2018.

"Orientação: Milton Roberto Heinen".

1. Agrometeorologia. 2. Balanço hídrico. 3.  
Aprendizado de máquina. I. Título.

**JOSE LUIS JUAREZ RUELAS**

**MODELAGEM DO PARÂMETRO DE IRRIGAÇÃO: UM ESTUDO DE CASO PARA  
O CAPIM SUDÃO BRS ESTRIBO**

Dissertação apresentada ao Programa de Pós-graduação em Computação Aplicada da Universidade Federal do Pampa, como parte dos requisitos para a obtenção do título de Mestre em Computação Aplicada.

Área de concentração: Tecnologias para produção agropecuária

Dissertação defendida e aprovada em: 18 de dezembro de 2018.  
Banca examinadora:

---

Prof. Dr. Milton Roberto Heinen  
Orientador  
UNIPAMPA

---

Dra. Márcia Cristina Teixeira da Silveira  
EMBRAPA

---

Prof. Dr. Sandro da Silva Camargo  
UNIPAMPA

---

Prof. Dr. Naylor Bastiani Perez  
EMBRAPA

“A ciência mais útil é aquela cujo fruto é o mais transmissível”

Leonardo Da Vinci

(1452-1519, artista, cientista, engenheiro)

## **DEDICO**

A: Bertha, Zenaida, Nestor, Diana, Ignacio  
e Martha minha família e razão de ser.

## **AGRADECIMENTO**

Ao Prof. Dr. Gustavo Trentin, pela orientação, pelos valiosos ensinamentos, estímulo e amizade. Muito obrigado Prof. Gustavo pelo tempo compartilhado.

Ao Prof. Dr. Milton Heinen, pela orientação, ensinamentos e generosidade em compartilhar conhecimentos, durante a minha pós-graduação.

Ao Programa de Pós-Graduação em Computação Aplicada e à Empresa Brasileira de Pesquisa Agropecuária EMBRAPA Pecuária Sul, aos seus professores, pesquisadores, colegas e amigos.

À Banca examinadora pela predisposição e o tempo dedicado na avaliação deste trabalho.

À Organização dos Estados Americanos (OEA), ao Grupo Coimbra de Universidades Brasileiras (GCUB) e à Organização Pan-Americana da Saúde (OPAS/OMS), que por meio do Programa de Alianças para a Educação e Capacitação (PAEC) me brindaram a oportunidade financeira de realizar o Programa de Pós-Graduação em Computação Aplicada (PPGCAP).

## RESUMO

A disponibilidade hídrica é um dos fatores fundamentais para o sucesso da produção agrícola. Em condições naturais, os cultivos recebem o suprimento da água por meio da precipitação e, em épocas de estiagem, são necessárias tarefas de manejo com irrigação. A irrigação é uma técnica artificial destinada ao fornecimento de água para os cultivos, e para que esta tarefa possa ser bem manejada, precisa-se do parâmetro de irrigação. O parâmetro de irrigação é o principal indicador ao fazer tarefas de irrigação, normalmente expresso em milímetros. No verão, as condições meteorológicas podem restringir a disponibilidade hídrica, o que vem a causar problemas nas culturas e cadeias produtivas. Para fazer frente a este problema de baixa disponibilidade hídrica, em parceria entre Embrapa Pecuária Sul e Sulpasto, foi desenvolvido e lançado o capim-sudão BRS Estribo, que é uma forrageira anual de verão, que vem ganhando preferência por parte dos produtores. Esta forrageira vem sendo adotada porque, se bem manejada, tem um elevado potencial de produção. Neste estudo apresentamos um modelo empírico que, a partir de uma data de semeadura, dados meteorológicos e parâmetros da forrageira, calcula o parâmetro de irrigação. Também é mostrado que os modelos CART, SVM e ANN conseguem prever o parâmetro de irrigação com um  $R^2$  de 0,986; 0,985 e 0,988 respectivamente, a partir do modelo empírico. Os resultados apresentados neste estudo indicam que o modelo empírico e os modelos de inteligência artificial podem ser utilizados na aplicação prática do planejamento e gestão dos recursos hídricos.

Palavras-chave: Agrometeorologia. Balanço hídrico. Aprendizado de máquina.

## ABSTRACT

Water availability is one of the key factors for the success of agricultural production. Under natural conditions, the crops are supplied with water through precipitation, and during drought periods irrigation management tasks are required. Irrigation is an artificial technique used to supply water to crops, and in order for this task to be well managed, the irrigation parameter is needed. The irrigation parameter is the main indicator when doing irrigation tasks, usually expressed in millimeters. In summer, weather conditions can restrict water availability, which causes problems in crops and productive chains. To tackle this problem, in partnership between Embrapa Pecuária Sul and Sulpasto, the capim-sudão BRS Estribo was developed and launched, which is an annual summer forage, which has been gaining preference among producers. This forage has been adopted because, if well managed, it has a high potential of production. In this study we present an empirical model, which based on a sowing date, meteorological data and forage parameters, calculates the irrigation parameter. It is also shown that the CART, SVM and ANN models can predict the irrigation parameter with an  $R^2$  equal to 0,986; 0,985 and 0,988 respectively, from the empirical model. The results presented in this study indicate that the empirical model and artificial intelligence models can be used in the practical application of planning and management of water resources.

Keywords: Agrometeorology. Water balance. Machine learning.



## LISTA DE FIGURAS

Figura 1 – Representação de uma árvore de decisão -----	27
Figura 2 – Função de perda para a regressão do SVM -----	29
Figura 3 – Esquema de um neurônio artificial -----	31
Figura 4 – Função de ativação ReLU-----	33
Figura 5 – Técnica de retropropagação do erro-----	33
Figura 6 – Etapas da Pesquisa -----	40
Figura 7 – Modelo empírico-----	42
Figura 8 – Processo de aprendizado máquina -----	48
Figura 9 – Fluxo dos componentes para o aprendizado de máquina no Orange ----	50
Figura 10 – Valores médios das temperaturas máximas, mínimas e valores acumulados de precipitação e evapotranspiração da Estação Meteorológica Principal da Embrapa Pecuária Sul, Bagé - RS, para o período de janeiro de 2007 a maio de 2018.-----	56
Figura 11 – Valores diários da água disponível, precipitação e precipitação efetiva em mm ao longo do ciclo do capim-sudão BRS Estribo, em função da semeadura simulada com data 01/10/2016 a 31/05/2017.-----	57
Figura 12 – Valores diários da necessidade de água disponível, precipitação efetiva, irrigação, evapotranspiração máxima, irrigação, balanço hídrico em mm ao longo do ciclo do Capim-Sudão BRS Estribo, em função da semeadura simulada com data 01/10/2016 a 31/05/2017-----	58
Figura 13 – Soma térmica acumulada em graus dias, acumulados em função das semeaduras, simuladas durante os anos 2007 a 2018.-----	59
Figura 14 – Evapotranspiração máxima acumulada em mm, em função das semeaduras, simuladas durante os anos 2007 a 2018.-----	60
Figura 15 – Precipitação acumulada em mm, em função das semeaduras, simuladas durante os anos 2007 a 2018.-----	61
Figura 16 – Irrigação acumulada em mm, em função das semeaduras, simuladas durante os anos 2007 a 2018.-----	62
Figura 17 – Parâmetro de irrigação em mm, real e estimado pelo modelo KNN, em função da época de semeadura, simulada entre 01/10/2016 e 31/05/2017. -----	63
Figura 18 – Parâmetro de irrigação em mm, real e estimado pelo modelo CART, em função da época de semeadura, simulada entre 01/10/2016 e 31/05/2017. ---	63

Figura 19 – Parâmetro de irrigação em mm, real e estimado pelo modelo SVM, em função da época de semeadura, simulada entre 01/10/2016 e 31/05/2017. ---	64
Figura 20 – Parâmetro de irrigação em mm, real e estimado pelo modelo ANN, em função da época de semeadura, simulada entre 01/10/2016 e 31/05/2017. -----	65
Figura 21 – Dispersão do parâmetro de irrigação pelos modelos de KNN, CART, SVM, ANN em relação ao modelo empírico.-----	68

## LISTA DE TABELAS

Tabela 1 - Resumo do trabalhos correlatos -----	38
Tabela 2 - Variáveis meteorológicas e Irrigação -----	43
Tabela 3 - Variáveis de entrada e saída para os modelos de aprendizado de máquina -----	49
Tabela 4 - Hiperpâmetros para os modelos de aprendizado de máquina-----	52
Tabela 5 - Critério de interpretação do desempenho dos métodos de estimativa do parâmetro de irrigação, pelo índice “c”. -----	55
Tabela 6 - Índices de rendimento dos modelos de inteligência artificial -----	65
Tabela 7 - Desempenho dos modelos de inteligência artificial pelo índice “c” -----	67

## LISTA DE ABREVIATURAS E SIGLAS

AD	-	Água Disponível
ANA	-	Agência Nacional de Águas
ANN	-	Artificial Neural Network
BH	-	Balanço Hídrico
CAD	-	Capacidade de Armazenamento de Água
CADin	-	CAD inicial
CADf	-	CAD final
CART	-	Classification and Regression Trees
DIG	-	Gráficos de informação dirigida
ENOS	-	<i>El Niño</i> Oscilação Sul
ES	-	Épocas de Semeadura
ETm	-	Evapotranspiração máxima do cultivo
ETo	-	Evapotranspiração de referência
GD	-	Graus Dias
Kc	-	Coefficiente de Cultura
KNN	-	k-Nearest Neighbors
MAE	-	Mean Absolute Error
mm	-	milímetros
MSE	-	Mean Squared Error
Pe	-	Precipitação efetiva
Pi	-	Perdas iniciais
Pr	-	Perdas por escoamento superficial
Preci	-	Precipitação pluviométrica
R <sup>2</sup>	-	Coefficiente de determinação
RMSE	-	Root Mean Squared Error
St	-	Soma térmica
SVM	-	Support Vector Machine
Tb	-	Temperatura base
Tmin	-	Temperatura mínima do ar
Tmax	-	Temperatura máxima do ar
UTD	-	Unidades Térmicas Diárias

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>14</b>
1.1	Problema.....	17
1.2	Justificativa .....	17
1.3	Objetivos.....	18
1.4	Escopo de trabalho.....	18
1.5	Principais contribuições .....	18
1.6	Organização do trabalho .....	19
<b>2</b>	<b>REVISÃO DE LITERATURA.....</b>	<b>20</b>
2.1	O capim-sudão BRS Estribo .....	20
2.1.1	Temperatura e ciclo de desenvolvimento do capim-sudão BRS Estribo ..	21
2.1.2	Consumo de água e necessidade de irrigação .....	21
2.1.3	Precipitação .....	23
2.1.4	Irrigação .....	24
2.2	Inteligência artificial .....	25
2.2.1	K vizinhos mais próximos (KNN) .....	26
2.2.2	Árvore de classificação e regressão (CART) .....	27
2.2.3	Máquinas de vetores de suporte (SVM).....	28
2.2.4	Redes neurais artificiais (ANN).....	30
2.3	Trabalhos correlatos .....	34
2.3.1	Revisão sistemática .....	34
2.3.2	Detalhamento dos trabalhos .....	35
<b>3</b>	<b>METODOLOGIA.....</b>	<b>39</b>
3.1	Metodologia de pesquisa .....	39
3.2	Etapas do processo da pesquisa .....	40
3.3	Descrição de estudo .....	41
3.4	Modelo empírico .....	41
3.4.1	Dados meteorológicos.....	43
3.4.2	Parâmetros da cultura.....	43
3.5	Modelos de inteligência artificial.....	47
3.5.1	Pré-processamento dos dados .....	49

3.5.2	Processo de aprendizado de máquina .....	50
3.5.3	Hiperpâmetros para os modelos de aprendizado de máquina.....	51
3.6	Avaliação do desempenho dos modelos propostos .....	54
4	RESULTADOS .....	56
4.1	Resultados do modelo empírico.....	56
4.2	Resultados dos modelos de inteligência artificial .....	62
4.3	Avaliação do desempenho dos modelos.....	66
5	CONSIDERAÇÕES FINAIS.....	69
	REFERÊNCIAS.....	71
	ANEXO.....	77

## 1 INTRODUÇÃO

O parâmetro de irrigação ou lâmina de irrigação é a principal métrica ao fazer tarefas de irrigação, normalmente expresso em milímetros (mm). Segundo Lima (1999), denomina-se irrigação o conjunto de técnicas artificiais destinadas ao fornecimento de água para os cultivos, em quantidade suficiente e no momento certo, proporcionando o volume hídrico no solo suficiente para o crescimento das plantas, corrigindo a distribuição natural das chuvas.

O capim-sudão BRS Estribo é uma forrageira anual de verão, lançada em 2013, desenvolvida pela equipe de melhoramento vegetal da Embrapa Pecuária Sul e Sulpasto, com base no processo de seleção, visando alta qualidade e produtividade como principais características. Desta maneira, o capim-sudão BRS Estribo faz parte das cultivares lançadas pela Embrapa Pecuária Sul, que tem como finalidade disponibilizar ao produtor uma opção para melhorar a produtividade e facilitar o planejamento de oferta de forragem, prevendo um período de escassez de água. O pecuarista do sul vem usando, além do campo nativo, forrageiras desenvolvidas e lançadas pela Embrapa Pecuária Sul, o que contribui para incrementar os ganhos com gado de corte ou leite em diferentes tipos de propriedade (EMBRAPA, 2014). O capim-sudão BRS Estribo oferece importantes vantagens quando comparada a outras forrageiras de verão. Por exemplo, quando comparado com o sorgo forrageiro e o milho, o capim-sudão BRS Estribo apresenta um ciclo mais longo (um mês e meio a mais de forragem para o consumo animal). Em comparação ao sorgo, o capim-sudão BRS Estribo não apresenta riscos de intoxicação aos animais nos estágios iniciais de desenvolvimento. O capim-sudão BRS Estribo é adaptável a vários tipos de solos, apresentando boa tolerância ao pastejo e ao pisoteio e, alto perfilhamento após o pastejo. (SILVEIRA *et al.*, 2015).

O capim sudão, além de ser responsivo ao fotoperíodo (variável climática a qual identifica o período de luminosidade solar em uma região e época do ano, ou seja, o período que vai do amanhecer ao pôr do sol), é muito sensível ao déficit e excesso de água. Assim, pequenos períodos com estiagem no subperíodo semeadura-emergência e reprodutiva comprometem o sucesso da produção de forragem. O capim-sudão BRS Estribo também possui boa tolerância à deficiência hídrica. A necessidade hídrica para atingir o rendimento potencial do capim-sudão BRS Estribo varia entre 350 mm a 700 mm, condicionada ao desenvolvimento ao longo do ciclo,

com base nas condições meteorológicas locais, características da cultura e manejo do pastejo (SILVEIRA *et al.*, 2015).

De acordo com Medrano *et al.* (2007), a disponibilidade hídrica é um fator limitante na produção agrícola. Em condições naturais, as culturas são abastecidas de água por meio da precipitação pluviométrica, que varia em quantidade e distribuição durante os meses do ano. Nos meses em que a precipitação pluviométrica é insuficiente à demanda das culturas, ocorre o estresse hídrico, gerando perdas na produção (SACCON, 2018). Geralmente na região do Rio Grande do Sul ocorre déficit hídrico no período do verão, devido ao aumento da evapotranspiração e a insuficiente precipitação pluviométrica para a demanda hídrica das culturas. Considere-se que a precipitação é a entrada de água no ecossistema, enquanto que a evapotranspiração é a principal forma de saída (WREGE *et al.*, 2012).

Para Ávila *et al.* (1996), os meses mais críticos para as culturas em relação à precipitação são novembro, dezembro, janeiro e fevereiro. Seu estudo considerou a série histórica de 78 anos (1913–1990), e demonstrou que a probabilidade de ocorrência de precipitação pluvial é igual ou menor à 40% na região da Campanha do estado do Rio Grande do Sul.

A probabilidade da ocorrência da precipitação pluvial é associada à produtividade do cultivo. Berlato, Farenzena e Fontana (2005) demonstraram que no Rio Grande do Sul há uma associação às fases do fenômeno *El Niño* Oscilacao Sul (ENOS). A fase *El Niño* favorece a probabilidade da ocorrência da precipitação pluvial e a produção das culturas, o que poderia dar oportunidade à alta produtividade. Contrariamente, a fase *La Niña* reduz a probabilidade da ocorrência de precipitação pluvial, o que representa riscos de períodos longos de estiagem, tendo como consequência uma queda na produtividade.

Trentin *et al.* (2016) avaliaram o capim-sudão BRS Estribo submetido a diferentes disponibilidades hídricas 0%, 50%, 100% e 150% da evapotranspiração de referência (perda de água em milímetros por evaporação do solo e transpiração do cultivo de referência), em um experimento realizado na Embrapa Pecuária Sul. O período experimental iniciou no verão de 2014 e terminou no outono de 2015. A irrigação com nível de 50% da evapotranspiração de referência obteve 78,069 kg/hectare de matéria verde total, representando a maior produção do experimento, seguida de 69,309 kg/hectare para o tratamento com nível de irrigação de 100% da evapotranspiração de referência; 59,283 kg/hectare para tratamentos com nível de



irrigação de 150% da evapotranspiração de referência e, finalmente 57,604 kg/hectare para o tratamento sem irrigação.

Assim, os benefícios do capim-sudão BRS Estribo, quando bem manejado são observados não somente pela produção de forragem (kg/hectare) ou pelo ganho de peso animal na pastagem da forma produtividade (kg vivo/hectare), mas também pelo impacto positivo no sistema como um todo, que vão além da produção da forragem. Por exemplo, a redução de riscos causados pela estiagem, aumento da taxa de prenhez e a velocidade do ganho de peso animal. Com isso, é possível realizar a venda antecipada do animal no verão, antes do preço cair devido ao excesso de oferta, reduzindo a carga animal no outono, devido à fenologia e o efeito na produtividade. Além disso, num enfoque de sistema de produção, é fundamental considerar que a viabilidade econômica não é o preço de venda do produto final, nem o custo de produção, mas sim a produtividade da pastagem por hectare, a mesma que é a base de uma cadeia produtiva (EMBRAPA, 2017). Portanto se fazem necessárias tarefas de planejamento ou manejo na produtividade.

Estas tarefas são importantes pois a região Sul do Brasil tem grande parte de sua economia associada ao agronegócio, onde as características do clima e suas variações podem determinar anos mais, ou menos favoráveis para a produção agrícola e criação de animais. O agronegócio é uma atividade que ao longo dos anos tem contribuído para a economia nacional. Em 2017 o PIB do agronegócio foi de R\$ 1,42 trilhão, representando 22% do PIB brasileiro e o PIB da pecuária foi de 433 bilhões, 31% do agronegócio (ABIEC, 2018). O Brasil possui o maior rebanho bovino comercial do mundo, e é um dos maiores exportadores mundiais de carne em toneladas e em faturamento. Segundo Abiec (2018), em 2017 foram reportadas 13,5 milhões de cabeças de bovinos, o que representa 6,21% da participação do rebanho do estado no total do Brasil. Nos últimos 7 anos, o rebanho bovino no Rio Grande do Sul se manteve relativamente estável, tendo por aptidão produtiva, prioritariamente, o gado de corte (INFORMATIVO NESPRO & EMBRAPA PECUÁRIA SUL, 2018).

## 1.1 Problema

Em condições naturais, os cultivos recebem o suprimento da água por meio da precipitação e, em épocas de estiagem, são necessárias tarefas de manejo com irrigação para corrigir as deficiências hídricas nos cultivos. O parâmetro de irrigação é um dos indicadores no planejamento forrageiro em termos de escassez de recursos hídricos. O cultivar capim-sudão BRS Estribo, produz abaixo do seu potencial em condições de deficiência ou excesso hídrico. Por isso, é necessário conhecer quando e o quanto irrigar ao longo do seu ciclo.

Assim, o problema de pesquisa deste trabalho consiste em determinar os momentos e a quantidade hídrica que melhor caracterizam as condições solo-água-planta-atmosfera para suportar o manejo da irrigação do capim-sudão BRS Estribo ao longo de seu ciclo.

## 1.2 Justificativa

O desenvolvimento deste trabalho radica no impacto produtivo, econômico, ambiental e tecnológico que poderia ter o cálculo do parâmetro de irrigação, já que os modelos propostos poderiam tornar-se uma ferramenta para os produtores. Assim, o impacto produtivo poderia ocorrer na adoção e manejo do capim sudão BRS Estribo como estratégia para períodos com riscos de baixa disponibilidade hídrica. O impacto econômico poderia ocorrer no processo de dar suporte, não só ao manejo da irrigação em sistemas de produção de forragem, representada na forma em kg/hectare, mas também na produtividade da forragem pelo ganho de peso animal em kg vivo/hectare, que pode ser representado em preço do bovino gordo na forma R\$/kg vivo. Por outra parte, o recurso hídrico bem manejado pode ter um impacto ambiental, porque a água é um recurso natural limitado que tem a agricultura como a maior consumidora. Finalmente, o impacto tecnológico poderia ocorrer no processo da apropriação da informação como elemento chave na tomada de decisões no setor agropecuário, como também o processo de generalizar a irrigação, a partir dos dados e de modelos empíricos e de aprendizado de máquina. Por isso salienta-se a importância deste trabalho para suportar o manejo da irrigação do capim-sudão BRS Estribo ao longo de seu ciclo.

### **1.3 Objetivos**

Neste contexto, o objetivo geral deste trabalho é modelar o parâmetro de irrigação que melhor caracterize o desenvolvimento do capim-sudão BRS Estribo ao longo de seu ciclo. Para este fim, têm-se os seguintes objetivos específicos:

- Modelar empiricamente o parâmetro de irrigação que melhor caracterize o desenvolvimento do capim-sudão BRS Estribo ao longo de seu ciclo;
- Aplicar modelos de inteligência artificial para aprender e prever o parâmetro de irrigação do capim-sudão BRS Estribo ao longo de seu ciclo;
- Avaliar o desempenho dos modelos na determinação do parâmetro de irrigação do capim-sudão BRS Estribo ao longo de seu ciclo.

### **1.4 Escopo de trabalho**

Sendo um trabalho interdisciplinar das áreas agropecuária e computação, o trabalho terá como objetivo principal a modelagem do parâmetro de irrigação com base em parâmetros do cultivo e dados meteorológicos da estação Embrapa Pecuária Sul, Bagé, RS. Além disso, propõe-se o uso de 4 modelos de inteligência artificial para poder generalizar a determinação do parâmetro de irrigação e avaliar o desempenho dos modelos.

### **1.5 Principais contribuições**

A principal contribuição deste trabalho é desenvolver, aplicar e validar um modelo que permita obter o parâmetro de irrigação com as variáveis solo, planta, água e atmosfera e, conseqüentemente, preservar os recursos hídricos e otimizar a produção, bem como avaliar a possibilidade de extrapolar o uso do modelo para outras culturas forrageiras, que apresentam comportamento semelhante ao capim-sudão BRS Estribo.

## 1.6 Organização do trabalho

Este trabalho é composto por cinco capítulos, os quais estão estruturados da seguinte forma: No **Capítulo 2**, denominado Revisão de Literatura, estabelece-se a fundamentação teórica para manejo do capim-sudão BRS Estribo, a temperatura e ciclo de desenvolvimento do capim-sudão BRS Estribo, o consumo de água e necessidade de irrigação, a precipitação e a irrigação, assim como o referencial teórico para os modelos de inteligência artificial com foco no aprendizado de máquina. O **Capítulo 3**, denominado metodologia, é constituído pelas fases e métodos para o trabalho, bem como pela apresentação do modelo empírico proposto para o cálculo do parâmetro de irrigação e a aplicação dos modelos de inteligência artificial. No **Capítulo 4**, denominado resultados, são discutidos os resultados obtidos, contrastando os valores obtidos pelo modelo empírico e os modelos de inteligência artificial. E, por fim, no **Capítulo 5**, são apresentadas as considerações finais.

## 2 REVISÃO DE LITERATURA

Neste capítulo serão apresentados conceitos correspondentes ao objetivo do trabalho. Por conseguinte, na **Seção 2.1** serão descritos os aspectos relativos da irrigação do capim-sudão BRS Estribo. A **Seção 2.2** descreve os conteúdos referentes aos modelos de inteligência artificial e, finalmente, na **Seção 2.3** será apresentado o detalhamento dos trabalhos correlatos.

### 2.1 O capim-sudão BRS Estribo

O capim-sudão BRS Estribo é uma forrageira anual de verão, lançada em 2013. Desenvolvido pela equipe de melhoramento vegetal da Embrapa Pecuária Sul e Sulpasto, com base no processo de seleção, visando a produtividade como principal objetivo (EMBRAPA, 2014). O capim-sudão BRS Estribo complementa a cultivares lançadas pela Embrapa Pecuária Sul, permitindo montar uma cadeia de produção de forragem dentro de um sistema de produção estratégico, especialmente porque apresenta boa tolerância à deficiência hídrica, sendo bem adaptado aos estados do Paraná, Santa Catarina e Rio Grande do Sul (SILVEIRA *et al.*, 2015).

Além disso, o capim-sudão BRS Estribo apresenta boas taxas de perfilhamento, rebrota e rápido crescimento. Foram observadas folhas próxima aos 26 cm, com taxa de aparecimento de folhas de 0.27 cm/perfilho/dia, taxa de alongamento das folhas em torno de 10 cm/perfilho/dia, taxa de alongamento do colmo 1.4 cm/perfilho/dia e a cada 4 dias surge uma nova folha nos perfilhos, sendo o perfilho é a unidade básica de crescimento das gramíneas. O número de folhas vivas é uma constante genotípica e particular para cada planta, o BRS estribo mantém cerca de 8 folhas por perfilho, com uma taxa de senescência foliar de 1.79 cm/perfilho/dia, tendo as folhas uma duração de vida média de 31 dias. Portanto, este cultivar apresenta um maior potencial de crescimento e desenvolvimento quando se tem condições favoráveis. Porém vale salientar que o valor nutritivo das plantas forrageiras está intimamente relacionado ao manejo realizado (SILVEIRA *et al.*, 2015).

As sementes do capim-sudão BRS Estribo podem ser realizadas desde outubro até fevereiro para Rio Grande do Sul. O plantio inadequado desta forrageira pode a expor a condições meteorológicas que podem limitar a produção até anular a produção da espécie. Segundo Silveira *et al.* (2015), o ideal é fazer a sementeira com

temperatura do solo superior a 18°C a fim de obter uniformidade na emergência das plantas. Temperaturas inferiores a 10°C não aportam energia para o crescimento vegetativo do capim-sudão BRS Estribo.

### **2.1.1 Temperatura e ciclo de desenvolvimento do capim-sudão BRS Estribo**

Juntamente com a disponibilidade de água e nutrientes, a temperatura é um dos elementos meteorológicos que mais influencia no desenvolvimento vegetativo (KÖRNER; HILTBRUNNER, 2018). Silveira *et al.* (2015) consideram que o capim-sudão BRS Estribo cresce em temperaturas do ar entre 11°C e 34°C e, nesse sentido, a temperatura ideal para seu crescimento e desenvolvimento está próxima de 30°C.

Assim, o desenvolvimento desejado do capim-sudão BRS Estribo pode ser relacionado com a temperatura média do ar, utilizando o método da soma térmica (ST), conhecida também como unidades térmicas diárias (UTD) ou graus dia (GD). Neste método de análise, considera-se uma temperatura mínima abaixo da qual a planta paralisa seu desenvolvimento (temperatura base). Acima desta temperatura base, ocorre a soma térmica com o desenvolvimento do cultivo (BRUNINI *et al.*, 1976).

A soma térmica também é utilizada como estratégia para a implantação da pastagem, o manejo de pragas e a planificação de intervalos de cortes ou pastejo. Assim, a soma térmica para o intervalo da sementeira até a emergência é de 56°C, da emergência até o primeiro pastejo cerca de 358°C e, para os seguintes pastejos 281°C (MALCORRA *et al.*, 2017).

### **2.1.2 Consumo de água e necessidade de irrigação**

Considera-se, atualmente, que a quantidade total de água na terra, de 1386 milhões de km<sup>3</sup>, tenha permanecido de modo aproximadamente constante durante os últimos 500 milhões de anos. Do volume total de água da terra, 97,5% é de água salgada formada pelos oceanos, e somente 2,5% é água doce. A maior parte dessa água doce (68,7%) está armazenada nas calotas polares e geleiras. Lagos e rios são as formas de armazenamento de água mais acessíveis para o uso humano, representado apenas 0,27% de água doce da terra, e cerca de 0,007% do volume

total. Observa-se que, mesmo tendo 1386 milhões de km<sup>3</sup> de água na Terra, a porção de água doce disponível ao uso humano é apenas 0,007% (LIMA, 2001).

A água é um recurso vital e sua disponibilidade é um fator limitante da produção agrícola (MEDRANO *et al.*, 2007). Em condições naturais, as culturas são abastecidas de água por meio da precipitação pluviométrica, que varia em quantidade e distribuição durante os meses do ano. Nos meses em que a precipitação pluviométrica é insuficiente à demanda das culturas, ocorre o estresse hídrico gerando perdas na produção (SACCON, 2017).

Geralmente, na região do Rio Grande do Sul ocorre déficit hídrico no período do verão, devido ao aumento da evapotranspiração e a insuficiente precipitação pluviométrica para a demanda hídrica das culturas. Considere-se que a precipitação é a entrada de água no ecossistema, enquanto que a evapotranspiração é a principal forma de saída (WREGGE *et al.*, 2012).

Neste contexto, considera-se o capim-sudão BRS Estribo como tolerante à deficiência hídrica, desde que o solo permaneça com umidade de no mínimo 20%. Quando a umidade do solo é inferior a 20%, as plantas sofrem alterações fisiológicas, como o fechamento estomático e, conseqüentemente, redução no crescimento. Assim, a necessidade hídrica para atingir o rendimento potencial do capim-sudão BRS Estribo varia entre 350 mm a 700 mm, condicionada ao desenvolvimento ao longo do ciclo, com base nas condições meteorológicas locais, características da cultura e manejo do pastejo (SILVEIRA *et al.*, 2015).

Trentin *et al.* (2016) obtiveram a maior produção de matéria seca do capim-sudão BRS Estribo com uma irrigação deficitária de 50% da evapotranspiração de referência. Em contraste, a irrigação utilizando uma reposição de 150% da evapotranspiração de referência gerou uma menor produção da matéria seca, semelhante ao tratamento que não recebeu irrigação.

O conhecimento da necessidade hídrica é de considerável relevância no planejamento das atividades relacionadas à agricultura. Portanto, o parâmetro de irrigação torna-se um indicador que, com o correto manejo pode reduzir os danos causados por déficit hídrico e economizar a mão de obra, energia elétrica ou diesel utilizado no processo de irrigação, ajudando de forma eficiente na preservação do recurso hídrico.

### 2.1.3 Precipitação

A precipitação é definida como a deposição de qualquer forma de água em estado líquido ou sólido, proveniente da atmosfera - chuva, granizo, neve, neblina, chuvisco e orvalho (CAVIGLIONE *et al.*, 2000), que, normalmente, é expressa em milímetros. Uma chuva de 1 mm equivale ao volume de 1 Lm<sup>-2</sup>.

Naturalmente, a precipitação é a entrada de água no ecossistema, enquanto que a evapotranspiração é a principal forma de saída. Uma maneira simples de avaliar a disponibilidade hídrica climática é através da comparação da precipitação pluvial com a evapotranspiração potencial. Neste contexto, os meses mais críticos para as culturas na Região Sul em relação à precipitação são novembro, dezembro, janeiro e fevereiro. Uma vez que, a probabilidade de ocorrência de precipitação pluvial é igual ou menor do que 40% na região da Campanha do estado do Rio Grande do Sul, em um estudo no qual se considera a série histórica de 78 anos (1913 – 1990), enfatiza-se a necessidade do planejamento da irrigação (ÁVILA *et al.*, 1996).

Esta probabilidade da ocorrência da precipitação pluvial é associada à produtividade do cultivo, podendo acrescentar ou diminuir a variabilidade da precipitação pluvial em situações do fenômeno do *El Niño*-Oscilação Sul (ENSO), que é caracterizado por anomalias, positivas (*El Niño*) ou negativas (*La Niña*), de temperatura da superfície do mar no pacífico equatorial. Este fenômeno climático faz parte de um ciclo natural global do clima, uma fase quente conhecida como *El Niño* e uma fase fria conhecida como *La Niña*. Berlato, Farenzena e Fontana (2005) demonstraram que no Rio Grande do Sul há uma forte tendência do “*El Niño*” em favorecer a probabilidade da ocorrência da precipitação pluvial, e a produção das culturas, o que poderia dar oportunidade à alta produtividade. Contrariamente, em situações de “*La Niña*”, existe uma baixa probabilidade da ocorrência de precipitação pluvial, o que representa períodos longos de estiagem e, conseqüentemente, uma baixa produtividade dos cultivos.

Em contraste, a precipitação efetiva é a diferença entre a precipitação total e as diferentes perdas como escoamento superficial, perdas iniciais e evaporação da água interceptada pela vegetação. A utilização da precipitação efetiva é de grande relevância, porque constitui a água disponível no solo e é um dos elementos básicos a serem considerados na equação do balanço hídrico para determinar os requisitos de irrigação das culturas (ROMERO; GRANÃ, 1999). No manejo correto da irrigação,



a água a ser aplicada na cultura deve consistir na diferença entre a demanda determinada pela evapotranspiração e a precipitação efetiva (SILVA *et al.*, 1994).

#### 2.1.4 Irrigação

Denomina-se irrigação o conjunto de técnicas destinadas ao fornecimento de água para os cultivos em quantidade suficiente e no momento certo, podendo corrigir a distribuição natural das chuvas, proporcionando um teor de umidade no solo suficiente para o crescimento das plantas (LIMA; FERREIRA; CHRISTOFIDIS, 1999).

No Brasil o potencial de solos aptos para a irrigação estão estimados em 29.564.000 hectares, o que representa aproximadamente 3,5% da área total do território nacional. Enquanto isto, para o Rio Grande do Sul, o potencial é 2.165.000 hectares, e isso representa 7,3% do total das áreas potencialmente aptas à irrigação (ANA, 2018).

No Brasil as áreas equipadas para a irrigação. Em 2006, eram 4.545.533 hectares, e em 2015, eram 6.954.710 hectares, o que representa um crescimento de 35%. Enquanto isso, no Rio Grande do Sul, a área irrigada em 2006 foi 997.108 hectares, e em 2015 foi 1.368.327 hectares, o que representa um crescimento de somente 27%. No entanto, o método de irrigação por superfície predomina no Rio Grande do Sul (78%) na rizicultura, seguida da aspersão com o uso de pivôs centrais (6%), representando os principais métodos de irrigação, e as demais culturas irrigadas por outros métodos (16%) (ANA, 2018).

Embora se reconheça os benefícios relacionados à irrigação, ainda há dificuldades em se dimensionar sua importância. Assim, em qualquer planejamento e/ou operação no manejo da irrigação, deve-se considerar parâmetros que dependem da interação solo-água-planta-atmosfera. Estes planejamentos também devem considerar aspectos sociais e ecológicos, mantendo as condições favoráveis ao bom desenvolvimento do cultivo, minimizando os custos e aumentando a eficiência no uso da água (DRUMOND; AGUIAR, 2005).

É evidente que os períodos com déficit hídrico e sem irrigação afetam principalmente o crescimento e o desenvolvimento da planta, bem como a produção de matéria seca e, nessa condição, o uso da irrigação torna-se fundamental. A fim de aumentar a eficiência da água, Trentin *et al.* (2016) avaliaram o capim-sudão BRS Estribo submetido a diferentes disponibilidades hídricas 0, 50, 100 e 150% da

evapotranspiração de referência. O experimento foi realizado na Embrapa Pecuária Sul com início no verão e término no outono de 2015. A irrigação com nível de 50% (irrigação total 137,1 mm) da evapotranspiração de referência obteve 78.069 kg/hectare de matéria verde total, representando a maior produção do experimento; seguida de 69.309 kg/hectare para o tratamento com nível de irrigação de 100% (irrigação total 274,2 mm) da evapotranspiração de referência; 59.283 kg/hectare para tratamentos com nível de irrigação de 150% (irrigação total 411,3 mm) da evapotranspiração de referência e, finalmente 57.604 kg/hectare para o tratamento sem irrigação.

Por conseguinte, o momento e a quantidade de água aplicada em cada irrigação depende de vários fatores que fazem parte do processo produtivo, tais como: a capacidade de armazenamento de água do solo, o tipo da cultura, o estágio de desenvolvimento da cultura, a estação do ano e as condições meteorológicas (ALLEN *et al.*, 2006).

## **2.2 Inteligência artificial**

A inteligência artificial pode ser definida como um ramo da ciência da computação, que se ocupa pelo estudo e criação de sistemas que possam manifestar um comportamento inteligente, e realizar tarefas complexas com um nível de competência que é equivalente ou superior ao de um especialista humano (LUGER, 2004).

Dentre os modelos da inteligência artificial, abordamos o aprendizado de máquina supervisionado, a partir da discussão de suas áreas mais importantes de pesquisa e aplicação. Essa visão geral revela um campo novo e promissor, cujo interesse principal é encontrar um modo efetivo de entender e aplicar técnicas inteligentes para a solução de problemas, especificamente com a finalidade de aprender e prever o parâmetro de irrigação.

No presente trabalho, serão abordados 4 modelos de inteligência artificial que foram elegidos de acordo ao domínio do problema e à natureza do parâmetro de irrigação, estes modelos são dos tipos de aprendizagem supervisionada que, por meio de treinamento, teste e validação, são capazes de determinar o parâmetro de irrigação, que é parte do objetivo deste trabalho de pesquisa. Assim, o modelo *K* vizinhos mais próximos é apresentado na seção 2.2.1, as árvores de classificação e

regressão são apresentadas na seção 2.2.2, a seção 2.2.3 trata das máquinas de vetores de suporte e a seção 2.2.4 aborda o modelo de redes neurais artificiais.

### 2.2.1 K vizinhos mais próximos (KNN)

O método  $K$  vizinhos mais próximos (KNN, do inglês *k-nearest neighbors*) é um método de aprendizado não paramétrico para tarefas de regressão (ALTMAN, 1992). O algoritmo KNN usa  $K$  vizinhos para estimar variáveis contínuas. O objetivo é otimizar o resultado da média ponderada da distância inversa com os  $K$  vizinhos multivariados mais próximos (AGUIRRE-SALADO *et al.*, 2011). O algoritmo de aproximação tem a forma de:

$$\hat{y}_i = \frac{\sum_{i=1}^k \left( \frac{1}{d^2} \right) y_i}{\sum_{i=1}^k \left( \frac{1}{d^2} \right)}$$

Onde:

$\hat{y}_i$  = Média ponderada da distância inversa com os  $K$  vizinhos multivariados mais próximos;

$d$  = distância Euclidiana;

$y_i$  = observações para a média.

Em geral, a distância Euclidiana ( $d$ ) entre os pontos do espaço euclidiana  $n$ -dimensional, é definida como:

$$d = \sqrt{\sum_{i=1}^k (x_i - y_i)^2}$$

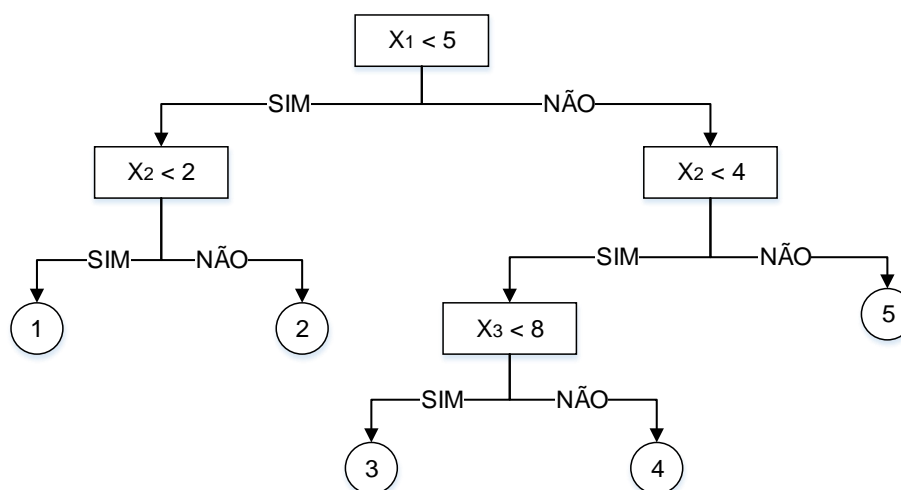
O valor ideal para  $K$  é escolhido com base no RMSE mais baixo usando validação cruzada. A validação cruzada é outra maneira de determinar retrospectivamente um bom valor de  $K$  usando um conjunto de dados independente para validar esse valor. É importante mencionar que o KNN é muito suscetível a superajuste devido à maldição da dimensionalidade (ALTMAN, 1992).

## 2.2.2 Árvore de classificação e regressão (CART)

As árvores de classificação e regressão (CART, do inglês *classification and regression trees*) são modelos versáteis da inteligência artificial. Estes modelos de predição supervisionados são utilizados em várias áreas como: mineração de dados, aprendizado de máquina, análise de dados e tomada de decisão em geral, sendo uma das formas de algoritmos de aprendizado mais simples e de maior sucesso (OLSON; WU, 2017)

O modelo, em geral, processa os dados com a finalidade de dividi-los em grupos. As árvores de classificação e regressão são eficazes em problemas com resultados categóricos, mas podem ser aplicadas a problemas contínuos (GÉRON, 2017). Para dados contínuos, o resultado é um número contínuo, que geralmente é a média da variável dependente (WITTEN *et al.*, 2016). O modelo da árvore de decisão está baseado em regras e condições que ocorrem de forma sucessiva para gerar como saída uma decisão. Sendo possível sua representação em diagramas como o da Figura 1 (DAYCHOUN, 2013).

Figura 1 – Representação de uma árvore de decisão



Fonte: Daychoun (2013)

A figura 1 apresenta a estrutura da árvore, onde cada nó interno corresponde a um teste do valor de uma propriedade, o nó raiz representa a variável que predomina no sistema, os ramos dos nós são rotulados como os resultados possíveis do teste e cada folha da árvore especifica o valor a ser retornado se aquela folha for alcançada.

O algoritmo CART funciona dividindo o conjunto de treinamento em dois subconjuntos, um único recurso  $k$  e um limite  $t_k$  (por exemplo: “*temperatura media*”  $> = 23 \text{ }^\circ\text{C}$ ) (GÉRON, 2017). O par  $(k, t_k)$  produz os subconjuntos mais puros, a função de custo que tenta minimizar o erro médio quadrático é dada por:

$$J(k, t_k) = \frac{m_{left}}{m} MSE_{left} + \frac{m_{right}}{m} MSE_{right} \quad \text{where} \quad \begin{cases} MSE_{node} = \sum_{i \in node} (\hat{y}_{node} - y^{(i)})^2 \\ \hat{y}_{node} = \frac{1}{m_{node}} \sum_{i \in node} y^{(i)} \end{cases}$$

A predição de uma instância em uma árvore de regressão atravessa a árvore iniciando pela raiz, até chegar ao nó folha que prediz o valor contínuo. Esta predição é simplesmente o valor resultante da média das instâncias de treinamento associadas a este nó folha (FRIEDMAN; HASTIE; TIBSHIRANI, 2009).

### 2.2.3 Máquinas de vetores de suporte (SVM)


As máquinas de vetores de suporte (SVM, do inglês support vector machine) são métodos de inteligência artificial baseados na teoria da dimensão Vapnik-Chervonenkis e o princípio de risco estrutural (SMOLA; SCHÖLKOPF, 2004). As SVM estão bem estruturadas para generalizar dados ainda não vistos, e podem ser aplicadas a problemas de regressão como uma forma de otimizar os limites de generalização nos problemas de regressão (ROGEL-SALAZAR, 2018).

As SVM's apresentam um bom rendimento na resolução de problemas de reconhecimento de amostras não lineares e de padrões com alta dimensionalidade, apresentando vantagens únicas ao superar a maldição da dimensionalidade (Em matemática e estatística, a maldição da dimensão refere-se aos vários fenômenos que surgem ao analisar e organizar dados de espaços de múltiplas dimensões que não acontecem no espaço físico descrito geralmente com apenas três dimensões) e o excesso do aprendizado, isto devido ao princípio de minimização de risco estrutural ao fazer uso do kernel que não depende da dimensionalidade do espaço de entrada (DRUKER, *et al.*, 1997).

Para o algoritmo SVM (Figura 2) suponha-se que se tem dados de treinamento da forma:  $\{(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i)\} \subset X \times \mathbb{R}$ , onde  $x_i$  representa o espaço da entrada e,  $y_i$  representa o espaço da saída e,  $f(x)$ :

$$f(x) = \langle w, x \rangle + b \text{ with } w \in \mathbb{R}^n, b \in \mathbb{R}$$

Figura 2 – Função de perda para a regressão do SVM



Fonte: Smola & Schölkopf (2004)

O modelo tenta minimizar a norma  $\|w\|^2 = \langle w, w \rangle$ , da forma:

$$\text{minimizar } \frac{1}{2} \|w\|^2$$

$$\text{Sujeto a } \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon \end{cases}$$

A ideia é que a função  $f$  aproxima todos os pares  $(x_i, y_i)$  com precisão  $\varepsilon$ , neste caso o problema da otimização convexa é viável. No entanto, este não pode ser o caso, porque a ideia é generalizar, portanto, as variáveis de folga  $\xi_i, \xi_i^*$  são introduzidas para lidar com as limitações do problema de otimização que de outra forma seriam inviáveis, atingindo a forma:

$$\text{minimizar } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*)$$

$$\text{Sujeto a } \begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

Para problemas não lineares, as funções de núcleo transformam os dados em um espaço de características dimensionais mais altas para possibilitar a separação linear da seguinte forma:

$$y = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \cdot \langle \varphi(x_i), \varphi(x) \rangle + b$$

Onde:  $0 \leq \alpha_i \leq C \quad 1 \leq i \leq N$

$$y = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \cdot K(x_i, x) + b$$

Existem vários *Kernel* que podem ser usados nos modelos de SVM. Estes *Kernel* incluem a forma linear, polinomial, função de base radial (RBF) e sigmoide:

Funções *Kernel*

$$K(X_i, X_j) = \left\{ \exp\left(-\gamma |X_i - X_j|^2\right) \right\}$$

Onde:

$$K(X_i, X_j) = \phi(X_i) \cdot \phi(X_j)$$

Ou seja, a função *kernel* representa um produto escalar de pontos de dados de entrada mapeados para o espaço de características dimensionais superiores através de uma transformação  $\phi$ , sendo Gamma um parâmetro ajustável de certas funções do *kernel* (SMOLA; SCHÖLKOPF, 2004). O *kernel* tipo RBF é a escolha mais usada em SVM, isso se deve principalmente às respostas localizadas e finitas em toda a faixa real do eixo x (RASCHKA; MIRJALILI, 2017).

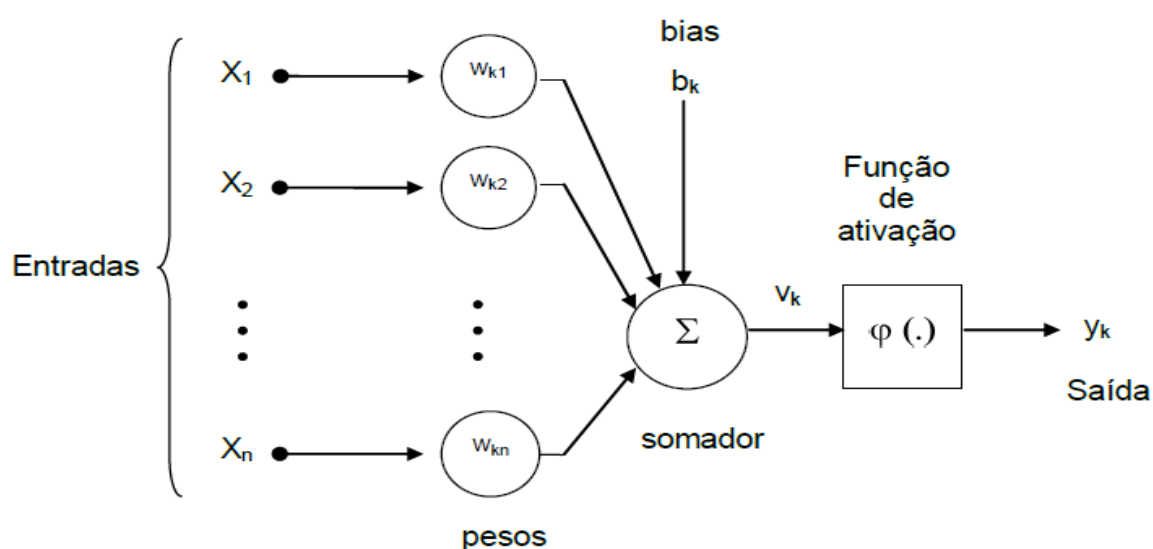
## 2.2.4 Redes neurais artificiais (ANN)

As redes neurais artificiais (ANN, do inglês *Artificial Neural Network*) são modelos que surgiram como uma tentativa de reproduzir o funcionamento do cérebro humano, e assim desenvolver sistemas capazes de realizar cálculos sem a intervenção humana. Deste modo, as redes neurais possuem a capacidade para resolver problemas de aproximação, predição e otimização, de forma que a partir dos exemplos analisados elas conseguem extrair as regras gerais que descrevem um problema e assim podem aplicar estas regras para a solução de novos exemplos não analisados anteriormente (LUGER, 2004).

### 2.2.4.1 Neurônio artificial

O neurônio artificial foi desenvolvido como uma simplificação matemática no funcionamento do neurônio humano (Figura 3) que tenta reproduzir as principais características destes referentes à forma em que se processa a aquisição de conhecimentos (ROSENBLATT, 1959).

Figura 3 – Esquema de um neurônio artificial



Fonte: Haykin (2001)

Um neurônio artificial é formado por entradas  $(x_1, x_2, \dots, x_n)$ , que recebem os sinais externos. Associado a cada entrada de um neurônio artificial, existem pesos  $(w_{k1}, w_{k2}, \dots, w_{kn})$ , que são os valores numéricos que representam a força das conexões existentes entre os diversos neurônios e, uma função de ativação  $(\varphi(\cdot))$ , que limita a combinação dos valores obtidos nas entradas e saídas, transmitindo os sinais recebidos e processados pelo neurônio para o exterior (BRAGA; LUDERMIR; CARVALHO, 2000).

### 2.2.4.2 Aprendizado do Perceptron

O tipo de neurônio artificial mais utilizado é o Perceptron, que foi originalmente desenvolvido por Rosenblatt (1959). Em termos matemáticos, a saída  $y_k$  de um Perceptron  $k$  com  $n$  entradas é descrita pela equação:



$$y_k = \varphi(v_k)$$

Onde  $\varphi(.)$  representa a função de ativação que normaliza o valor de saída do neurônio, e  $v_k$  é o campo local induzido, calculado pela equação:

$$v_k = \sum_{i=1}^m w_{ki} x_i + b_k$$

Onde  $x_1, x_2, \dots, x_n$  são os valores de entrada,  $w_{k1}, w_{k2}, \dots, w_{kn}$  são os pesos sinápticos do neurônio  $k$  e  $b_k$  é o *bias*, que é uma entrada especial que recebe sempre o valor 1 e que possui um peso associado que pode ser ajustado, assim como os demais pesos do neurônio.


A função de ativação  $\varphi(.)$  mais utilizada é *sigmoid*, definida através da função logística:

$$\varphi(v_k) = \frac{1}{1 + e^{-av_k}}$$

A Figura 4 mostra o gráfico da função *ReLU* (Unidade Linear Retificada), definida como  $f(x) = \max(0, x)$ . A função *ReLU* é não linear e, faz com que a saída de um neurônio seja normalizada entre os valores 0 e 1, e a função é usada no processo de aprendizado para gerar uma certa estabilidade no sistema, evitando que os pesos variem depois que o valor da saída já se encontra próximo a um dos extremos. A principal vantagem de usar a função *ReLU* sobre outras funções de ativação é que ela não ativa todos os neurônios ao mesmo tempo (RUMELHART; HINTON; WILLIAMS, 1986).

Para que o aprendizado seja possível, em uma rede neural à base de perceptrons, é necessário que seja fornecido um conjunto de treinamento com as saídas desejadas para cada exemplo. Este tipo de aprendizado, que é conhecido como aprendizado supervisionado, ocorre em diversas etapas, nas quais os dados são submetidos à rede neural para o ajuste dos pesos, que foram inicializados aleatoriamente.

Figura 4 – Função de ativação ReLU




Fonte: Haykin (2001)


### 2.2.4.3 Aprendizado por retropropagação

A tarefa de um perceptron multicamada é obter a saída desejada para as entradas de certos tipos de dados, com o objetivo de resolver problemas que não são linearmente separáveis (Figura 5). Com esse objetivo, a aprendizagem do perceptron utilizada pelo algoritmo consiste em determinar o erro na aproximação do valor desejado e propagá-lo retroativamente através das camadas ocultas, com a finalidade de atualizar os pesos dos neurônios locais. Este princípio é realizado até a estabilização dos pesos em função do erro (ROSENBLATT, 1959).

Na figura 5, também é apresentada: (a) propagação direta de sinais, (b) propagação no sentido inverso usando as mesmas ligações que em a. (c) propagação do erro usando a matriz de peso fixo, que é constante durante o processo de aprendizagem (LUGER, 2004).

Figura 5 – Técnica de retropropagação do erro





Fonte: Luger (2004)

Assim, as fases de propagação e retropropagação seguem sequencialmente uma a uma e formam um ciclo completo de aprendizado. Estes processos são repetidos iterativamente para cada exemplo de treinamento por  $n$ -épocas, até que o aprendizado seja concluído. O número de neurônios na camada oculta, assim como o número de camadas ocultas, depende do problema que está sendo abordado, de forma que não existe um valor padrão que sirva para a maioria dos casos (LUGER, 2004).

## 2.3 Trabalhos correlatos

Além dos eixos utilizados para criar o referencial teórico sobre a modelagem do parâmetro de irrigação de cultivos de capim-sudão BRS Estribo por meio de modelos de inteligência artificial, outros trabalhos referentes ao tema abordado foram estudados e selecionados.

Nesta seção serão descritos os trabalhos correlatos identificados na literatura que foram selecionados não somente pelo tema da irrigação, mas também pelo uso dos modelos de inteligência artificial. A seção 2.3.1 descreve a revisão sistemática nos repositórios sobre os conteúdos do estudo, e a seção 2.3.2 descreve o detalhamento dos trabalhos.

### 2.3.1 Revisão sistemática

A revisão foi feita em repositórios on-line para poder obter informações sobre a irrigação por meio de modelos de inteligência artificial. Os repositórios principalmente utilizados foram: Google acadêmico, ScieceDirect (Elsevier), SciELO, Scopus (Elsevier), Bases de Dados da Pesquisa Agropecuária (Embrapa), Alice (Embrapa) e EBSCOhost.

Na busca bibliográfica utilizou-se as principais palavras chaves:

- *Capim sudão AND "BRS estribo"*
- *"Sorghum sudanense L."*
- *Irrigation*
- *K-Nearest Neighbor AND regression*
- *Classification and Regression Trees*
- *Support vector machine AND regression*
- *Artificial neural network AND regression*

Entre os trabalhos pesquisados não foram encontrados trabalhos que fazem referência a irrigação do capim-sudão BRS Estribo utilizando modelos de inteligência artificial. Assim, o critério da seleção foi baseada nos conteúdos abordados por uma parte do capim-sudão BRS Estribo, e por outra do cálculo da irrigação por meio de modelos de inteligência artificial.

Dos trabalhos que possuíam ligação com a pesquisa, destaca-se os trabalhos de (ROMERO *et al.*, 2018), (HU *et al.*, 2017), (HASSAN-ESFAHANI; TORRES-RUA; MCKEE, 2015) e (GOAP *et al.*, 2018). Estes trabalhos tratam a irrigação aplicando modelos de inteligência artificial especificamente algoritmos de aprendizado máquina como: ANN, BRT e SVM.

### **2.3.2 Detalhamento dos trabalhos**

O trabalho realizado por Romero *et al.* (2018), intitulado "Estimativa do estado da água em vinhedos usando imagens multiespectrais de uma plataforma de UAV e algoritmos de aprendizado de máquina para o gerenciamento de programação de irrigação", teve como objetivo detectar remotamente o estado da água em vinhedos. Os métodos aplicados no estudo foram algoritmos de aprendizado estatístico para encontrar a correlação entre os índices estudados. Regressão simples e testes estatísticos não mostraram relações significativas entre as variáveis estudadas, porém os resultados de um algoritmo de aprendizado automático de tipo ANN obtiveram os resultados para os dados de treinamento, validação e teste de  $R = 0,8$ ;  $0,72$  e  $0,62$ , respectivamente.

O trabalho realizado por Hu *et al.* (2017), intitulado “Combinando inteligência humana e de máquina para derivar as regras comportamentais dos agentes para irrigação de águas subterrâneas”, cujo objetivo foi derivar as regras do comportamento da racionalidade limitada dos agentes e da escassez de dados. Assim, o estudo propõe uma abordagem "caixa cinza" para enfrentar o desafio, incorporando conhecimento de domínio especializado (inteligência humana) com técnicas de aprendizagem de máquina (inteligência artificial). Especificamente, se propõe o uso dos gráficos de informação dirigida (DIG), árvores de regressão reforçadas (BRT) e conhecimento de domínio para inferir os fatores causais e identificar as regras de comportamento a partir dos dados. Nesse contexto, um estudo é realizado para investigar o comportamento de água pelos agricultores no Centro-Oeste dos EUA. Os resultados confirmam que o comportamento de irrigação dos agentes é consistente com os requisitos reais de irrigação da cultura, especialmente em áreas secas. Portanto, pode-se concluir que a abordagem baseada em dados utilizando DIG e BRT supera a abordagem baseada em otimização, especialmente em termos de capturar a incerteza do comportamento dos agentes como um resultado de racionalidade limitada e imitando seu comportamento real.

O trabalho realizado por Hassan-Esfahani, Torres-Rua e Mckee (2015), intitulado “Avaliação da alocação ótima da água de irrigação para o sistema de irrigação pressurizada usando abordagem de balanço hídrico, máquinas de aprendizagem e dados de sensoriamento remoto”, modela a alocação ótima de água em relação à maximização da uniformidade de irrigação. A metodologia aplica imagens Landsat, dados meteorológicos locais e medições de campo, que descrevem as condições do balanço de água no solo. Assim, o modelo foi testado em uma fazenda cultivada com alfafa e aveia e equipada com um pivô central em Scipio, Utah. O modelo segue três etapas: A primeira usa uma rede neural artificial para determinar a umidade profunda do solo e a umidade superior do solo, com R-quadrado de 0.7 e 0.8, respectivamente, como resultado deste processo. A etapa seguinte utiliza o coeficiente Gini para representar a uniformidade da umidade do solo. Finalmente é utilizado o algoritmo genético para encontrar o valor mínimo do coeficiente Gini. Com base nos resultados de simulação e otimização obtidos com o modelo, o irrigador baseado em algoritmos genéticos na área de estudo poderia usar até 20% menos água em comparação aos procedimentos operacionais tradicionais.

O trabalho realizado por Goap *et al.* (2018), intitulado “Um sistema de gerenciamento de irrigação inteligente baseado em Internet das coisas (IoT) usando tecnologias de aprendizado de máquina e código aberto”, teve como objetivo propor um sistema de irrigação inteligente baseado em IoT. A inteligência do sistema proposto é baseada em aprendizado supervisionado e não supervisionado utilizando *Support Vector Machine* em sua forma de regressão e *k-means* para determinar a umidade do solo a partir de dados meteorológicos, dados de previsão meteorológica e diferenças da umidade do solo, e fazer a programação da irrigação. A abordagem *Support Vector Machines* e *k-means* forneceu maior precisão com menor erro quadrático médio (MSE, do inglês *Mean Squared Error*) (0,10) em comparação com a abordagem SVR (0,15) e, com R-quadrado de 0,98 em condições de estiagem. Finalmente o valor previsto da umidade do solo é melhor em termos de precisão e taxa de erro.

Estes trabalhos correlatos estão apresentados de forma resumida na Tabela 1. No processo da pesquisa foi possível identificar o estado da arte dos modelos de inteligência artificial e, verificar como estão sendo integradas nas distintas áreas do conhecimento humano, bem como no sector agropecuário.

Tabela 1 - Resumo do trabalhos correlatos

<b>Objetivo</b>	<b>Técnicas</b>	<b>Resultados</b>
Estimar o estado da água em vinhedos	ANN	Os resultados para o algoritmo da inteligência artificial de tipo ANN ( <i>Artificial Neural Network</i> ) são: treinamento, validação e teste de R=0,8; 0,72 e 0,62, respectivamente (ROMERO <i>et al.</i> , 2018).
Derivar regras do comportamento.	DIG BRT	A derivação de regras DIG ( <i>Directed Information Graph</i> ), consegue ótimos resultados, combinando a inteligência humana e modelos de aprendizagem máquina de tipo BRT ( <i>Boosted Regression Trees</i> ) (HU <i>et al.</i> , 2017).
Modelar a alocação da água.	ANN, GA	O resultado na determinação da umidade profunda do solo pela ANN apresenta R-quadrado de 0,7. O irrigador baseado em GA ( <i>Genetic Algorithm</i> ) consegue reduzir 20% do uso da água comparado a métodos tradicionais (HASSAN-ESFAHANI; TORRES-RUA; MCKEE, 2015).
Propor um sistema de irrigação inteligente	SVM, k-means	SVM ( <i>Support Vector Machine</i> ) & k-means em conjunto fornecem maior precisão com menor MSE (0,10) em comparação com a abordagem SVR (0,15). Para ambos casos R-quadrado de 0,98 (GOAP <i>et al.</i> , 2018).

Fonte: Autor (2018)

### 3 METODOLOGIA

Neste capítulo serão descritas as diversas metodologias seguidas para alcançar os objetivos do estudo. Por conseguinte, na **Seção 3.1** serão descritos os aspectos relativos à metodologia de pesquisa. A **Seção 3.2** descreve as etapas do processo da pesquisa. Na **Seção 3.3** será descrito o estudo. Na **Seção 3.4** será descrito o modelo empírico. Na **Seção 3.5** será descrito o modelo de inteligência artificial. Finalmente, a **Seção 3.6** descreve a avaliação do desempenho dos modelos propostos.

#### 3.1 Metodologia de pesquisa

A linha de pesquisa deste trabalho pertence ao tópico “modelagem computacional do sistema solo-planta-animal”, estabelecido pelo PPGCAP – UNIPAMPA/ EMBRAPA. Do ponto de vista da sua natureza, esta pesquisa é classificada como uma pesquisa aplicada. De acordo com a classificação proposta por Gil (2007), a pesquisa aplicada tem como objetivo gerar conhecimento para aplicação de seus resultados, contribuindo, portanto, para fins práticos, visando a solução para um problema encontrado na realidade. Dessa forma, esta pesquisa pretende contribuir de forma prática na modelagem para o cálculo do parâmetro de irrigação em cultivos de capim-sudão BRS Estribo. Do ponto de vista da abordagem do problema, a pesquisa é quantitativa. Para a pesquisa quantitativa, Gil (2007) explica que a preocupação é a de descrever com precisão as características, utilizando instrumentos padronizados como a coleta de dados, que conduzem a resultados de natureza quantitativa, bem como a natureza dos dados meteorológicos para extrair o conhecimento, gerar o modelo, simular os dados, analisar os dados, aprender dos dados, centrando-se na compreensão e explicação das relações de forma quantificável. Do ponto de vista dos objetivos do trabalho, a pesquisa é explicativa, pois têm como prioridade identificar os fatores que determinam a ocorrência dos fenômenos. Nesta etapa a pesquisa pretende contribuir com o modelo do parâmetro de irrigação, identificando e explicando a fenologia do capim-sudão BRS Estribo, explicando a razão, e os porquês das coisas (GIL, 2007). Do ponto de vista dos procedimentos técnicos, a pesquisa é experimental já que o objeto de estudo dentro dos procedimentos é o parâmetro da irrigação e, o processo de modelar, nos dá a



capacidade de manipular as variáveis e, assim, observar o comportamento do sistema e, portanto, a variável objeto de estudo (GIL, 2007).

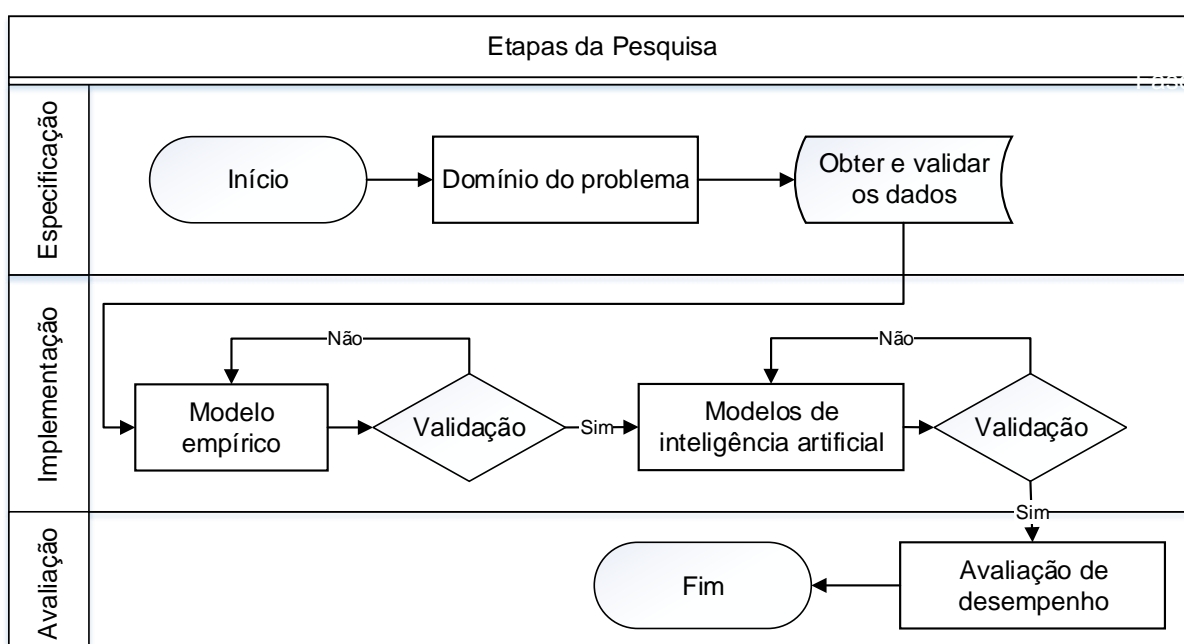
### 3.2 Etapas do processo da pesquisa

O modelo proposto neste trabalho é dividido em três etapas: Especificação, Implementação e Validação (Figura 6). A etapa da especificação estabelece os requisitos a partir do domínio do problema. O processo focaliza o problema, os objetivos, estabelece a base de dados a ser utilizada e define os métodos para gerar o modelo.

A etapa da implementação tem como objetivo principal desenvolver o modelo empírico e a validação pelo especialista. O modelo empírico permite emular o comportamento do parâmetro de irrigação a partir dos dados meteorológicos (2007-2018). Este processo também permite gerar dados que serão necessários para o aprendizado de máquina. Os dados gerados pelo modelo empírico foram usados para o aprendizado dos modelos de IA e para estimar o parâmetro de irrigação. Os resultados dos modelos serão avaliados segundo o erro dos modelos de IA.

Finalmente, na última etapa, foi avaliado o desempenho dos modelos propostos neste trabalho.

Figura 6 – Etapas da Pesquisa



Fonte: Autor (2018)

### 3.3 Descrição de estudo

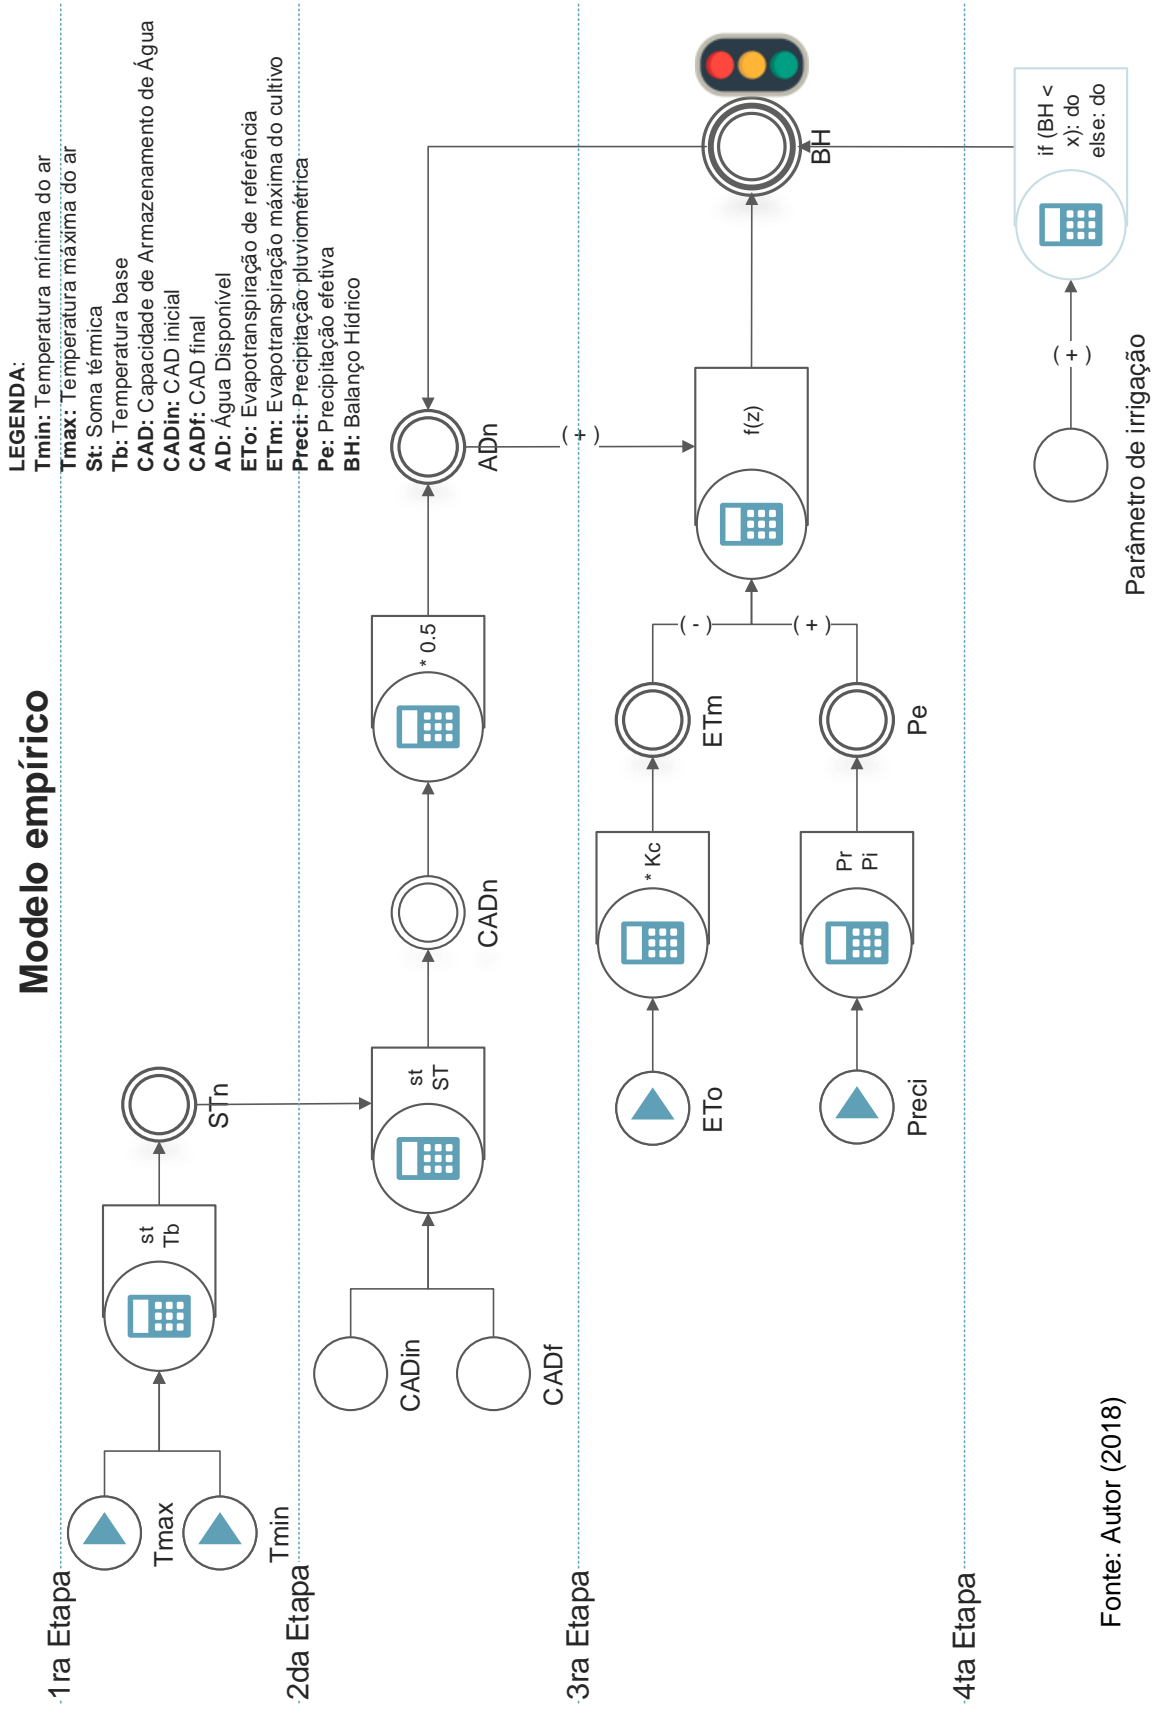
Este trabalho foi realizado em colaboração da Universidade Federal do Pampa (UNIPAMPA) e a Empresa Brasileira de Pesquisa Agropecuária - Embrapa Pecuária Sul, a fim de alcançar os objetivos propostos.

### 3.4 Modelo empírico

O modelo empírico baseia-se na experimentação e na lógica empírica, que, juntamente com a observação dos fenômenos e sua análise, permite construir conhecimento. Esse processo de modelagem nos permite observar as relações (fenologia) entre as variáveis e as características fundamentais do objeto de estudo (HAIM, 2005).

O processo de modelagem do parâmetro de irrigação mostrado na Figura 7, tem variáveis de entrada da forma solo-água-planta-atmosfera, procurando o balanço hídrico e a produção de forragem. Segundo Thornthwaite & Mather (1955) o balanço hídrico é definido como a contabilidade de entrada e saída de água do solo. A entrada de água é representada pela precipitação ou irrigação e a saída pela evapotranspiração. O método utilizado para o cálculo do balanço hídrico diário foi o de Thornthwaite & Mather (1955), descrito por Pereira, Villa-Nova & Sedyama (1997) e utilizado no roteiro de cálculo similar aos utilizados por Nied (2003) e por Silva (2008). O cálculo do parâmetro de irrigação no dia  $n$  foi realizado iterativamente, baseado no conteúdo de água armazenado no solo no dia  $(n-1)$ . Nos dias com irrigação, o parâmetro de irrigação foi considerado como entrada de água no cálculo do balanço hídrico, nos demais dias somente a precipitação efetiva foi considerada como entrada de água. Para ambas as formas de entrada de água no sistema, a evapotranspiração máxima foi considerada como a saída de água no cálculo do balanço hídrico.

Figura 7 – Modelo empírico



Fonte: Autor (2018)

### 3.4.1 Dados meteorológicos

A base de dados para este estudo foi disponibilizada pela Estação Meteorológica Principal da Embrapa Pecuária Sul, Bagé - RS, situando-se entre as coordenadas -31.347801°, -54.013292° (latitude, longitude) a 226 metros de altitude. Esta base de dados representa valores diários das variáveis apresentadas na Tabela 2, obtidas de 05/01/2007 até 31/05/2018 (2823 dias ou registros – Ano agrícola).

Tabela 2 - Variáveis meteorológicas e Irrigação

Nº	Variável	Descrição	Variável no sistema
1	Tmax	Temperatura máxima do ar (°C)	Entrada
2	Tmin	Temperatura mínima do ar (°C)	Entrada
3	Prec	Precipitação pluviométrica (mm)	Entrada
4	ETo	Evapotranspiração de referência (mm)	Entrada
5	Irrigação	Parâmetro de Irrigação (mm)	Saída

Fonte: Autor (2018)

### 3.4.2 Parâmetros da cultura

A cultura do capim-sudão BRS Estribo possui diversos parâmetros que afetam seu desenvolvimento. As próximas seções descrevem em detalhes os principais parâmetros da cultura.

#### 3.4.2.1 Épocas de semeadura

A simulação do desenvolvimento da cultura do capim-sudão BRS Estribo foi realizada para os dias 01 e 15 dos meses de outubro, novembro, dezembro, janeiro, fevereiro e março dos anos 2007 a 2018. O período preferencial para o plantio do capim-sudão BRS Estribo, em grande parte do Rio Grande do Sul, é a partir de outubro até fevereiro, com a capacidade de produção de forragem para os animais até maio-junho, dependendo em grande parte da ocorrência de geadas que podem antecipar o fim do ciclo do capim-sudão BRS Estribo (SILVEIRA *et al.*, 2015).

### 3.4.2.2 Subperíodos do capim-sudão BRS Estribo

A duração dos subperíodos foi determinada para a cultura do capim-sudão BRS Estribo (MALCORRA *et al.*, 2017) utilizando-se a soma térmica (ST) ou Unidades Térmicas Diárias (UTD). A soma térmica tem sido usada para representar o efeito da temperatura do ar sobre o crescimento e desenvolvimento das plantas (GILMORE; ROGERS, 1958; ARNOLD, 1960).

Nesse sentido, as UTD foram determinadas com base nas temperaturas máximas ( $T_{max}$ ) e mínimas ( $T_{min}$ ), possibilitando o cálculo da soma térmica em UTD no período de  $n$  dias, pela expressão:

$$ST = \sum_{i=1}^n \left[ \left( \frac{T_{max} + T_{min}}{2} \right) - T_b \right]$$

A soma térmica necessária para o capim-sudão BRS Estribo da semeadura-emergência é de  $56^{\circ}\text{C}\cdot\text{dia}^{-1}$ , da emergência-primeiro corte é de  $358^{\circ}\text{C}\cdot\text{dia}^{-1}$ , para os demais cortes, a soma térmica necessária é de  $281^{\circ}\text{C}\cdot\text{dia}^{-1}$ , considerando uma temperatura base ( $T_b$ ) de  $10^{\circ}\text{C}$  (MALCORRA *et al.*, 2017).

### 3.4.2.3 Evapotranspiração máxima

Para o cálculo da evapotranspiração máxima ( $ET_m$ ) da cultura, utilizou-se a evapotranspiração de referência ( $ET_o$ ) calculada e os coeficientes de cultura ( $K_c$ ) para o capim-sudão BRS Estribo (Allen *et al.*, 2006). Os  $K_c$  variam conforme os subperíodos de desenvolvimento do capim-sudão BRS Estribo. Finalmente a  $ET_m$  foi calculada por:

$$ET_m = (ET_o * K_c)$$

### 3.4.2.4 Capacidade de água disponível para os diferentes solos

A capacidade de armazenamento de água disponível do solo ( $CAD$ ) para a cultura do capim-sudão BRS Estribo foi calculada em uma escala diária conforme o aprofundamento radicular. Durante o subperíodo Semeadura-Emergência foi

considerada a  $CAD$  até a profundidade de 0,10 m; durante os cortes restantes a  $CAD$  foi calculada para cada dia ( $CAD_n$ ).

Para o cálculo da  $CAD_n$  desde a emergência, quando se tem a  $CAD$  inicial ( $CAD_{in}$ ) até o  $CAD$  final ( $CAD_f$ ), inclui-se a curva de crescimento sigmoidal do sistema radicular, apresentada por Dourado-Neto *et al.* (1999), com a função da fração da soma térmica total do subperíodo ( $ST$ ) atingida até o dia  $n$  ( $ST_n$ ) em substituição à fração do número de dias, considerando-se uma  $CAD_{in}$  de 15, uma  $CAD_f$  de 60 e um fator de forma do crescimento do sistema radicular ( $F$ ) referido para o capim-sudão BRS Estribo a 0,80.

$$CAD_n = CAD_{in} + \left( \frac{CAD_f + CAD_{in}}{2} \right) * \left\{ 1 - \cos \left[ \left( \pi^{\left( \frac{1}{F} \right)} * \frac{ST_n}{ST} \right)^F \right] \right\}$$

#### 3.4.2.5 Precipitação efetiva

A precipitação efetiva é somente o volume de água que infiltra no solo. O Serviço de Conservação de Recursos Naturais (NRCS, do inglês *Natural Resources Conservation Service*) utiliza o método da precipitação efetiva para determinar a infiltração da água no solo. A metodologia divide a precipitação em perdas por escoamento superficial e em perdas iniciais (FRIZZONE *et al.*, 2005).

$$Pi = \frac{5080}{CN} - 50,8$$

$$Pr = \frac{(Preci - 0,2s)^2}{(Preci + 0,8s)} \quad \text{quando } Preci > 0,2s$$

$$Pr = 0,0 \quad \text{quando } Preci < 0,2s$$

Sendo que:

$$s = 254 \left( \frac{100}{CN} - 1 \right)$$

Onde:

$Pi$  = perdas iniciais em decorrência da interceptação e do enchimento das rugosidades superficiais do solo;

$Pr$  = perdas por escoamento superficial;

$Preci$  = precipitação pluviométrica;

$CN$  = curva número, 91 para os solos com teor de silte + teor de argila > 50%

$s$  = parâmetro de retenção, adimensional.

$Pe$  = Precipitação efetiva, mm.

Considera-se que a evaporação influenciou em 25% das perdas iniciais e apenas 75% infiltra no solo, e que a variação do conteúdo de água no solo vai depender da água que infiltra (FRIZZONE *et al.*, 2005), e foi determinada pelas seguintes equações.

$$Pe = Preci - Pr - 0,25 * Pi, \text{ (quando } Preci > Pi)$$

$$Pe = 0,75 Preci \quad \text{(quando } Preci \leq Pi)$$

### 3.4.2.6 Necessidade de irrigação

A necessidade de irrigação foi determinada pelo quociente entre o conteúdo atual de água no solo e a  $CAD$ , determinados para o dia  $n$ , sendo a irrigação realizada no próximo dia (dia  $n + 1$ ). A irrigação foi realizada sempre que o conteúdo relativo de água no solo foi igual ou inferior ao limite ( $i$ ), em que:  $(1 - i) = p$ ,  $p$  é a fração de esgotamento de água no solo para os níveis de irrigação (TRENTIN *et al.*, 2016). Dessa forma, a necessidade de água disponível às plantas ( $AD$ ), para o processo de evapotranspiração, foi estabelecida pelo manejo de irrigação:

$$AD = (1 - i) * CAD$$

### 3.4.2.7 Balanço hídrico

Em concordância com Thornthwaite & Mather (1955) o balanço hídrico ( $BH$ ) foi definido como a contabilidade de entrada e saída de água do solo. A entrada de água é representada pela precipitação ou irrigação e a saída pela evapotranspiração. Desta maneira o método utilizado para o cálculo do BH diário foi o de Thornthwaite & Mather (1955), descrito por Pereira, Villa-Nova & Sedyama (1997) na seguinte equação:

$$BH = AD + Pe | Irrigação - ETm$$

### 3.4.2.7 Parâmetro de irrigação

O cálculo para obtenção do parâmetro de irrigação, no dia  $n$  foi realizado iterativamente, baseado no conteúdo de água armazenado no solo no dia  $(n - 1)$ . Nos dias com irrigação, o parâmetro de irrigação será considerado como entrada de água no cálculo do  $BH$ . Nos demais dias, a precipitação efetiva será considerada como entrada de água. Para ambos casos a evapotranspiração máxima da cultura será considerada como a saída de água, determinada pela seguinte equação:

$$\text{Irrigação} = AD + Pe - ETm - BH$$

O modelo empírico foi implementado usando a linguagem *Python* 3.6.5, no ambiente de *JupyterLab*, e as bibliotecas *pandas*, *numpy* e *plotly* a fim de suportar o objetivo deste trabalho, visando a filosofia de desenvolvimento de software de código aberto.

## 3.5 Modelos de inteligência artificial

Dentro da inteligência artificial existem distintas subáreas de estudo, uma das subáreas é o aprendizado de máquina que, tipicamente, está classificado em três subáreas: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço. Abordaremos o aprendizado supervisionado, discutido no capítulo 2.2 neste estudo. Especificamente a previsão da estimativa do parâmetro da irrigação é um problema de regressão (OLSON; WU, 2017).

Foram usados os 4 modelos de aprendizado de máquina do tipo supervisionado KNN, CART, SVM e ANN com o objetivo de aprender e prever o parâmetro de irrigação. A abordagem de modelos de inteligência artificial foi considerada necessária, porque sendo o modelo empírico um produto do especialista frente ao domínio do problema, sua capacidade poderia ser potencializada a partir dos modelos de aprendizado de máquina, dados meteorológicos e os parâmetros fenológicos próprios do capim-sudão BRS Estribo.

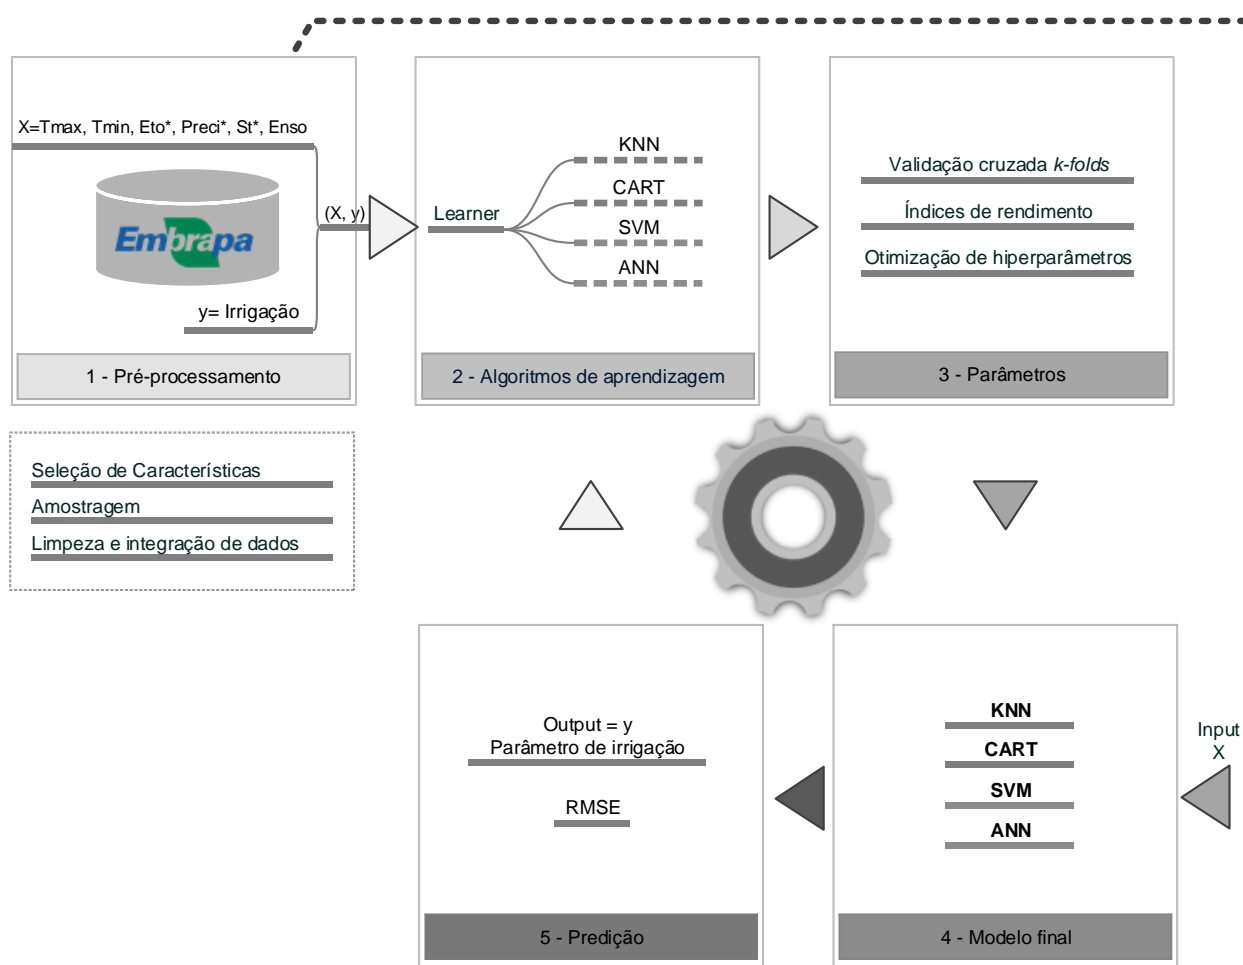
Na figura 8 é apresentado o resumo do processo de aprendizado de máquina para alcançar o objetivo deste estudo. O modelo tem como origem o processamento dos dados, que serão discutidos na seção 3.5.1. O processo continua para a abordagem dos algoritmos de aprendizagem, onde os dados para os algoritmos



estarão apresentados na forma  $(X, y)$ , onde  $X$  = conjunto de dados de entrada (Tabela 2) e  $y$  = saída desejada. Posteriormente os hiperparâmetros e métricas dos modelos serão configurados a fim de conseguir um modelo final que consiga aprender a partir dos conjuntos de dados e generalizar a determinação do parâmetro de irrigação.

Portanto, o enfoque de modelos de aprendizado de máquina baseado na regressão do parâmetro de irrigação, visa prever um valor que está próximo do valor real. Para determinar a eficiência dos modelos, a diferença entre os valores previstos e os valores reais (erro) se obterá através de várias medidas de erro MSE, RMSE, MAE e  $R^2$ , que serão analisados na seção 3.5.3.1 - índices de rendimento dos modelos de aprendizado máquina.

Figura 8 – Processo de aprendizado máquina



Fonte: Raschka e Mirjalili (2017)

### 3.5.1 Pré-processamento dos dados

O pré-processamento muitas vezes é a parte mais crucial do processo, pois a qualidade dos dados vai determinar a eficiência dos algoritmos. Nesse sentido foi realizada uma exploração dos dados, levando em consideração as estatísticas descritivas dos dados, tais como: valores mínimos, valores máximos, média, variância e sua normalidade, para poder avaliar possíveis inconsistências dos dados.

Nesta etapa, foi integrada a variável ENSO levando em consideração as respectivas datas. Do mesmo modo, serão integradas as variáveis da soma térmica acumulada gerada pelo modelo empírico. Finalmente, serão acumuladas e integradas as variáveis evapotranspiração e precipitação da forma evapotranspiração acumulada (Eto2) e precipitação acumulada (Preci2), apresentadas na Tabela 3. Este processo se faz necessário a fim de levar em conta as quantidades para aqueles registros onde será necessária irrigação.

Tabela 3 - Variáveis de entrada e saída para os modelos de aprendizado de máquina

Nº	Variável	Descrição	Variável no sistema
1	Tmax	Temperatura máxima do ar (°C)	Entrada
2	Tmin	Temperatura mínima do ar (°C)	Entrada
3	St	Soma térmica (°C)	Entrada
4	St2	Soma térmica acumulada (°C)	Entrada
5	ETo	Evapotranspiração (mm)	Entrada
6	ETo2	Evapotranspiração acumulada (mm)	Entrada
7	Preci	Precipitação pluviométrica (mm)	Entrada
8	Preci2	Precipitação pluviométrica acumulada (mm)	Entrada
9	ENSO	<i>El Niño</i> –Southern Oscillation (°C)	Entrada
10	Moment	Momento de irrigação (0 ou 1)	Entrada
11	Irrigação	Irrigação (mm)	Saída

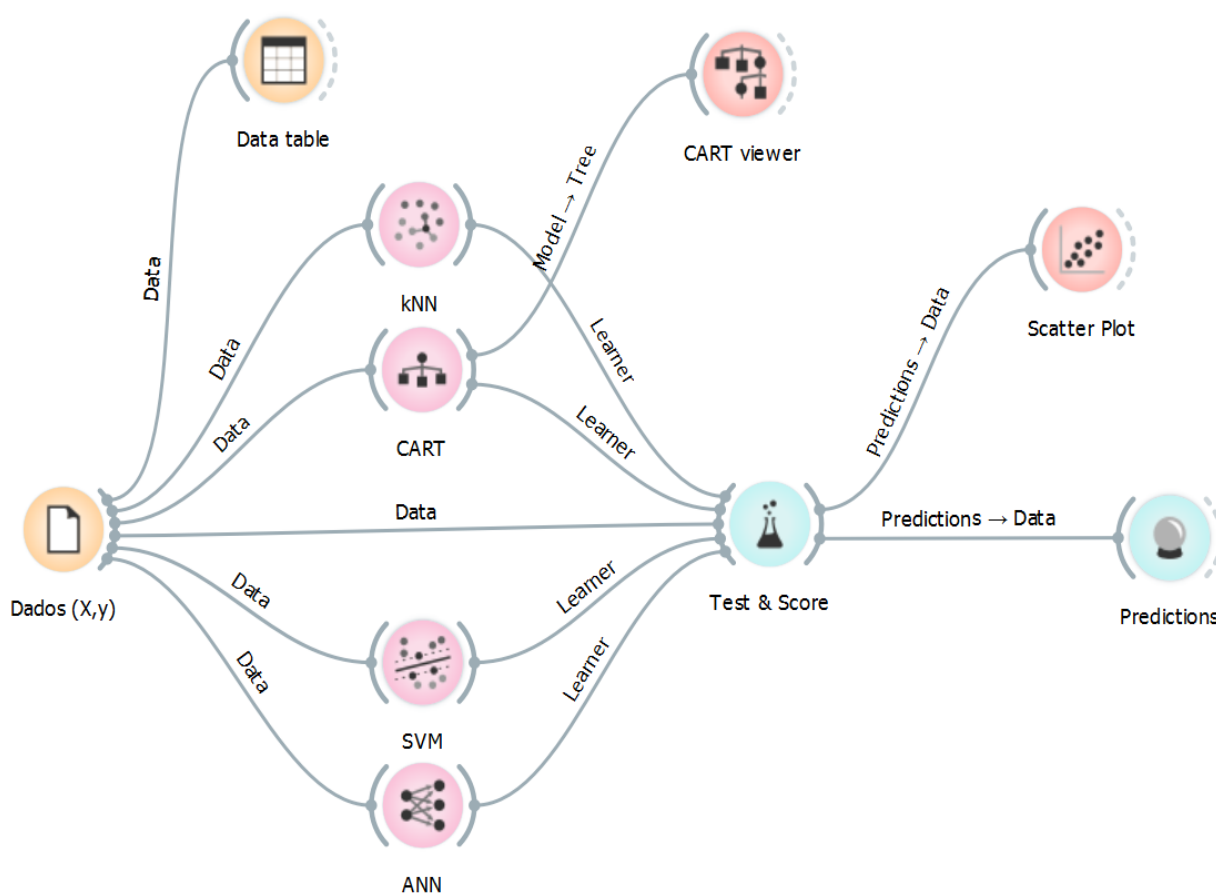
Fonte: Autor (2018)

### 3.5.2 Processo de aprendizado de máquina

Para a implementação dos 4 modelos de inteligência artificial, foi usada a ferramenta *Orange* (Figura 9). *Orange* é um kit de ferramentas de visualização de dados de código aberto, aprendizado de máquina e mineração de dados. Ele possui um *front-end* de programação visual para análise exploratória de dados e visualização interativa de dados e, também, pode ser usado como uma biblioteca *Python* (DEMŠAR *et al.*, 2013).

Os componentes de *Orange* são chamados de *widgets* e variam de simples visualização de dados, seleção de subconjuntos e pré-processamento, até avaliação empírica de algoritmos de aprendizado e modelagem preditiva.

Figura 9 – Fluxo dos componentes para o aprendizado de máquina no Orange



Fonte: Autor (2018)

A programação visual é implementada por meio de uma interface na qual os fluxos de trabalho são criados vinculando *widgets* predefinidos ou projetados pelo

usuário. Enquanto isso, os usuários avançados podem usar o Orange como uma biblioteca Python baseado em componentes para manipulação de dados, visualização de dados, aprendizado de máquina, mineração de dados e análise de dados.

Orange usa bibliotecas Python de código aberto para computação científica, como *numpy*, *scipy* e *scikit-learn*. O Orange é suportado no macOS, Windows e Linux. A instalação padrão inclui vários algoritmos de aprendizado de máquina, pré-processamento e visualização de dados em 6 conjuntos de *widgets* (dados, visualização, classificação, regressão, avaliação e não supervisionados). Funcionalidades adicionais estão disponíveis como complementos (bioinformática, fusão de dados e mineração de texto).

### 3.5.3 Hiperparâmetros para os modelos de aprendizado de máquina

A configuração dos hiperparâmetros para modelos de aprendizado de máquina foi realizada da seguinte forma:

- Para o modelo KNN, o número de vizinhos mais próximos foi determinado observando o RMSE do modelo, onde o número ideal de vizinhos mais próximos foi  $k = 7$ , utilizando como métrica a distância euclidiana;
- Para o modelo CART, os hiperparâmetros para a árvore de regressão incluíram o número mínimo de instâncias nas folhas, o mesmo foi determinado observando o RMSE do modelo, onde o número mínimo de instâncias na folha são 6, limitado a uma profundidade máxima da árvore a 6 níveis em relação ao nó principal;
- Para o modelo SVM, o *kernel* escolhido foi de função de base radial (RBF), com esta função SVM contém três hiperparâmetros principais a serem configurados. A RMSE do modelo depende de uma boa configuração do Custo (C), *regression loss epsilon* ( $\epsilon$ ) e dos parâmetros do kernel. Para o modelo SVM, o RMSE depende da configuração do Custo (C=10) que é o prazo de penalidade por perda, para tarefas de regressão dependente da configuração do *epsilon-SVR* ( $\epsilon = 0,10$ ) que define a distância dos valores verdadeiros dentro dos quais não há penalidade associada aos valores previstos. Para *gamma* ( $g = 0,20$ ) no kernel RBF, o valor recomendado é  $1/k$ , onde k é número dos atributos, ou  $g = \text{auto}$ . Finalmente a otimização dos parâmetros está dada pela tolerância numérica 0,01 e 500 iterações;

- Para o modelo ANN foi utilizado o tipo *Perceptron* multicamadas (MLP) com o algoritmo *backpropagation*. Os hiperparâmetros para a rede neural foram definidos em duas camadas ocultas com 16 e 8 neurônios respectivamente, esta configuração está determinada observando o RMSE do modelo. A função de ativação está dada pela função da unidade linear retificada (ReLU) e a otimização dos pesos é dada pelo método da descida do gradiente estocástico (SGD). O modelo ANN também utiliza o parâmetro Alpha = 0,0001 (L2: regularização *Ridge Regression*), com 100 iterações para permitir uma melhor convergência.

A configuração dos hiperparâmetros empregados nos modelos é apresentada na Tabela 4, as mesmas que estão baseadas no processo de aprendizado de máquina supervisionado (Figura 8), considerando os valores das variáveis de entrada e saída da Tabela 3. Processo que permite obter os valores desejados, possibilitando o aprendizado e evitando o *overfitting*. Este trabalho apresenta um enfoque analítico dos índices de rendimento dos modelos de inteligência artificial, dado que a qualidade dos modelos depende da configuração adequada dos hiperparâmetros. Nessa concepção, os hiperparâmetros foram determinados de forma empírica através de tentativa e erro buscando os melhores índices de rendimento para os modelos.

Tabela 4 - Hiperpâmetros para os modelos de aprendizado de máquina

(continua)

Modelo	Métricas dos algoritmos
KNN	Número de vizinhos $k = 7$ ; Métrica distância euclidiana
CART	Número de instâncias na folha = 6;
SVM	Profundidade máxima da árvore = 6 Custo $C=10$ ; épsilon-SVR $\epsilon = 0,10$ ; Kernel = RBF; $g = 0,20$ ; Alpha = 0,01; Iterações = 500

Tabela 4 - Hiperpâmetros para os modelos de aprendizado de máquina

Modelo	Métricas dos algoritmos
ANN	2 camadas ocultas com 16 e 8 neurônios; Função de ativação = ReLu; Solver = SGD; Alpha = 0,0001; Iterações = 100

Fonte: Autor (2018)

O processo de treinamento e teste utiliza a técnica de validação cruzada. O modelo de validação cruzada é uma técnica importante, usada no aprendizado de máquina para avaliar a variabilidade de um conjunto de dados e a confiabilidade de qualquer modelo treinado usando esses dados, a partir da qualidade dos parâmetros.

O modelo de validação cruzada divide aleatoriamente os dados de treinamento em partições chamadas *k-folds*. O modelo padrão utiliza 10 partições (*k-folds* =10). Os dados de entrada são divididos em 10 partes, em que uma está reservada para teste, e as outras 9 para treinamento. Esse processo é repetido 10 vezes e as métricas de avaliação são transformadas em médias. Isso ajuda a determinar como o modelo seria generalizado para novos conjuntos de dados. Após o teste do modelo, as métricas de avaliação são usadas para avaliar o desempenho do modelo treinado.

As métricas para avaliar os resultados depois de executar os experimentos (modelos de aprendizado de máquina) representam o erro. O erro representa a diferença entre o valor previsto e o valor verdadeiro. Estas métricas de avaliação medem o desempenho de previsão de um modelo de regressão em termos do desvio da média de suas previsões dos valores verdadeiros. Uma métrica de erro geral 0 significa que o modelo se ajusta perfeitamente aos dados.

### 3.5.3.1 Índices de rendimento para os modelos de aprendizado máquina

O desempenho dos modelos foi avaliado por meio de análise de regressão dos índices:

- A média dos quadrados dos erros (MSE, do inglês *Mean Squared Error*) é a média dos quadrados dos erros de previsão.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

- A raiz quadrada do quadrado médio do erro (RMSE, do inglês *Root Mean Squared Error*) é o valor do desvio padrão dos erros de previsão (resíduos). É uma medida de dispersão dos resíduos.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

- O erro médio absoluto (MAE, do *Mean Absolute Error*) é a média das magnitudes do erro, ignorando a direção.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- O coeficiente de determinação ( $R^2$ ) é a proporção da variância na variável dependente em termos da variável independente (quadrado da medida do coeficiente de correlação).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}$$

### 3.6 Avaliação do desempenho dos modelos propostos

Para avaliar estatisticamente o desempenho dos modelos propostos neste trabalho, procurou-se correlacionar os valores estimados com as medidas, tomando-se como base os indicadores estatísticos propostos por (CAMARGO; SENTELHAS, 1997), definidos da forma: correlação entre o parâmetro de irrigação real e parâmetro de irrigação modelos “r”; exatidão – índice de Willmott “d” e o desempenho dos modelos “c” (Tabela 5).

Matematicamente, esta aproximação é dada por um índice designado concordância, representado pela letra “d” (WILLMOTT *et al.*, 1985), cujos valores

variam de zero, para nenhuma concordância, a 1, para concordância perfeita. O índice é dado pela seguinte expressão:

$$d = 1 - \left[ \frac{\sum (P_i - O_i)^2}{\sum (|P_i - O| + |O_i - O|)^2} \right]$$

Onde  $P_i$  é o valor estimado,  $O_i$  é o valor observado e,  $O$  a média dos valores observados. O índice de desempenho dos modelos “c” é representado pelo produto dos índices de precisão “r” e de exatidão “d”, expressado da forma:

$$c = r * d$$

Devido ao fato de serem apresentados mais de um modelo de estimativa para o parâmetro de irrigação é importante ter um indicador, neste caso o índice “c” (Tabela 5), a fim de ter um critério de comparação de desempenho dos modelos na tarefa de estimativa do parâmetro de irrigação.

Tabela 5 - Critério de interpretação do desempenho dos métodos de estimativa do parâmetro de irrigação, pelo índice “c”.

Valor de “c”	Desempenho
>0,85	Ótimo
0,76 a 0,85	Muito Bom
0,66 a 0,75	Bom
0,61 a 0,65	Mediano
0,51 a 0,60	Sofrível
0,41 a 0,50	Mau
$\leq 0,40$	Péssimo

Fonte: Camargo & Sentelhas (1997)



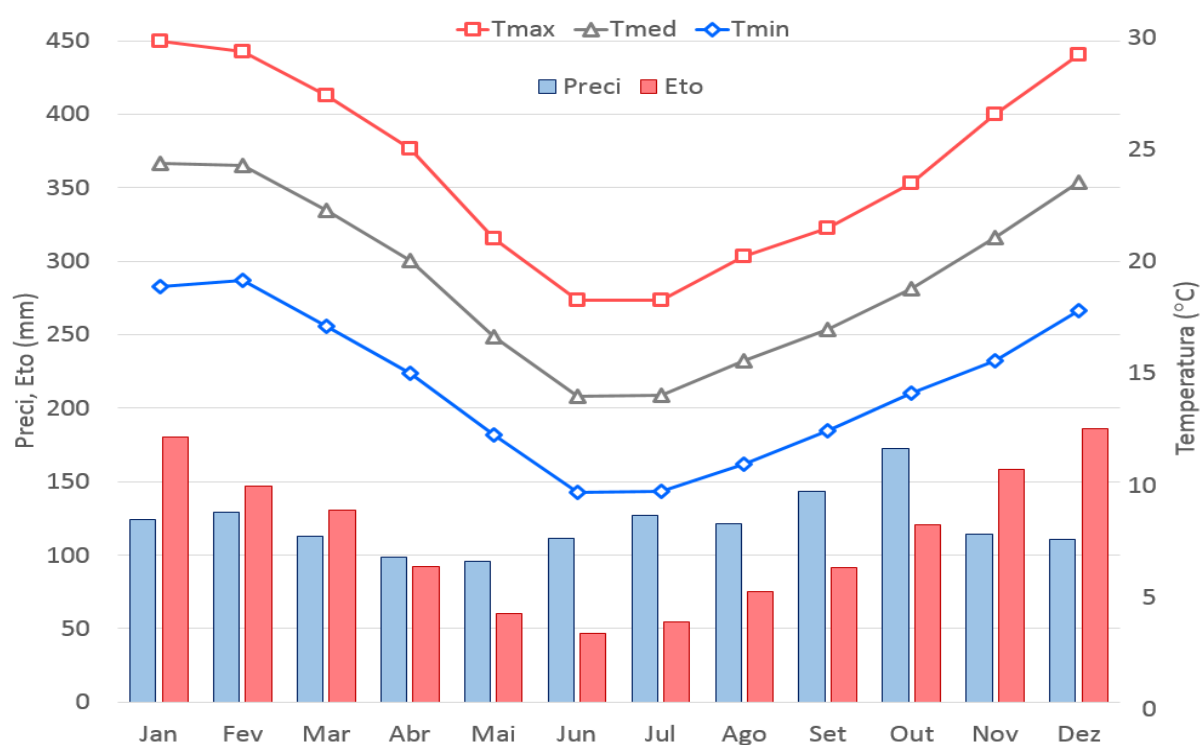
## 4 RESULTADOS

Neste capítulo são apresentados os resultados obtidos com o modelo de irrigação proposto neste trabalho. Por conseguinte, na **Seção 4.1** são apresentados os resultados do modelo empírico. Na **Seção 4.2** são apresentados os resultados dos modelos de inteligência artificial. Finalmente, a **Seção 4.3** apresenta o desempenho dos modelos propostos.

### 4.1 Resultados do modelo empírico

O modelo empírico tem como variáveis de entrada temperaturas máximas, mínimas, precipitação e parâmetros da cultura e como variável de saída o parâmetro de irrigação. A Figura 10 mostra a distribuição das variáveis de entrada ao longo dos anos de 2007 a 2018.

Figura 10 – Valores médios das temperaturas máximas, mínimas e valores acumulados de precipitação e evapotranspiração da Estação Meteorológica Principal da Embrapa Pecuária Sul, Bagé - RS, para o período de janeiro de 2007 a maio de 2018.

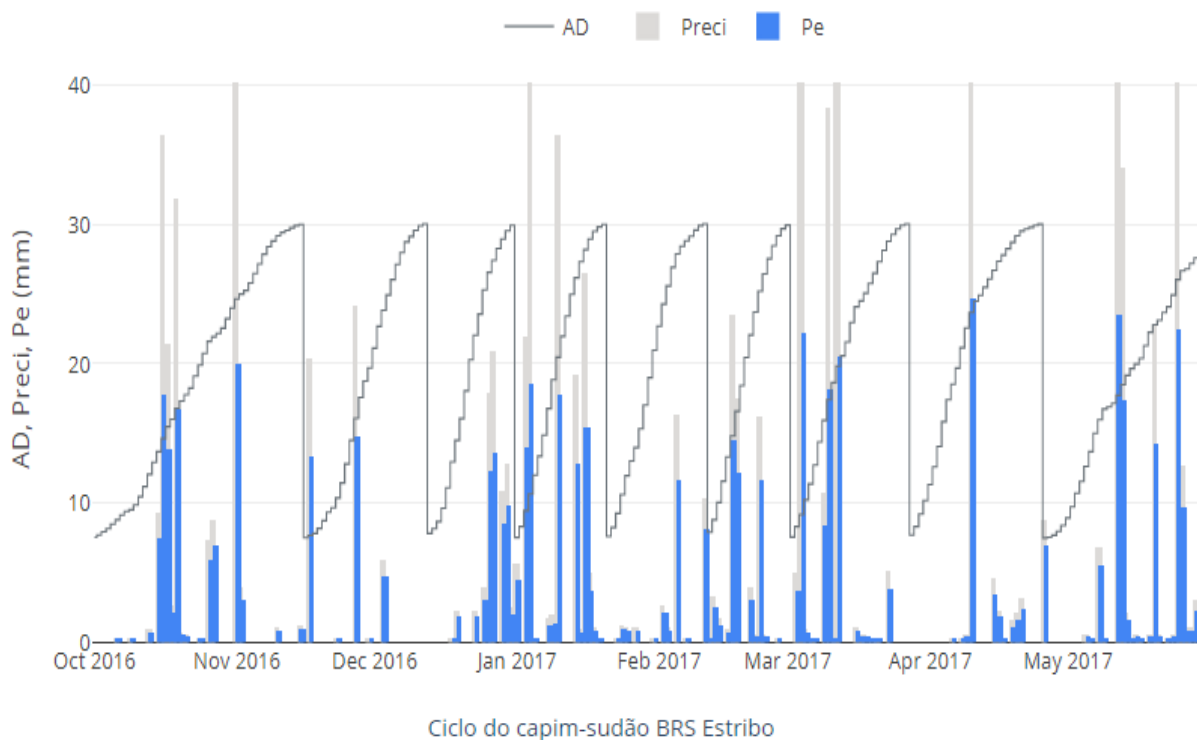


Fonte: Autor (2018)

Para gerar a simulação, foram imprescindíveis os parâmetros sobre o desenvolvimento do capim-sudão BRS Estribo e, assim, realizar o balanço hídrico sequencial para as épocas de semeadura dos anos 2007-2018. Foi modelado empiricamente o parâmetro de irrigação que melhor caracteriza o desenvolvimento do capim-sudão BRS Estribo. Desta maneira, determinou-se a necessidade de irrigação, principalmente devido à possível ocorrência de períodos prolongados de escassez de precipitação.

Na Figura 11 é apresentada a água disponível (AD) simulada para a semeadura realizada entre 01/10/2016 e 31/05/2017 para o capim-sudão BRS Estribo ao longo de seu ciclo. Além da necessidade de irrigação, é apresentado o comportamento da precipitação e da precipitação efetiva (que representa a água que no solo e esteve disponível para a planta).

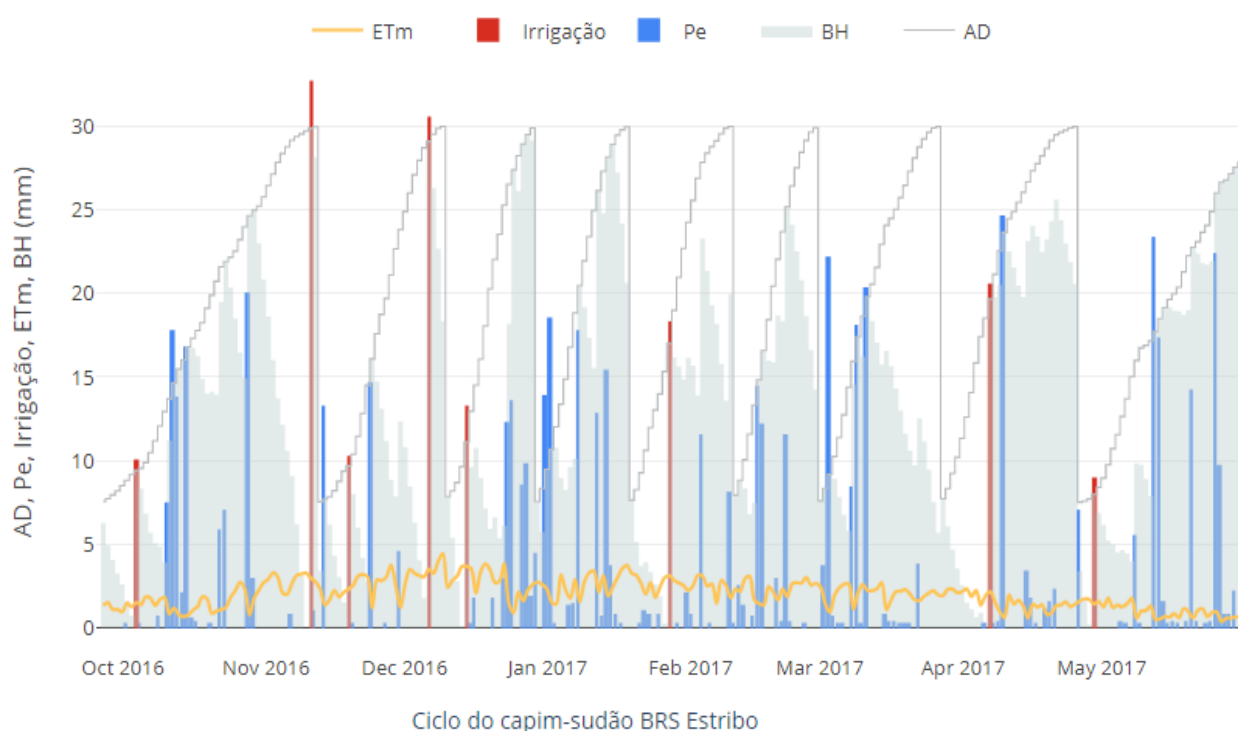
Figura 11 – Valores diários da água disponível, precipitação e precipitação efetiva em mm ao longo do ciclo do capim-sudão BRS Estribo, em função da semeadura simulada com data 01/10/2016 a 31/05/2017.



Fonte: Autor (2018)

Em concordância, o parâmetro de irrigação é um complemento da quantidade de água disponibilizada pelas precipitações (Figura 12). Desta forma, o capim-sudão BRS Estribo poderá ser suprido em suas necessidades hídricas nos dias com ausência de precipitação, procurando o balanço hídrico ao longo do seu ciclo.

Figura 12 – Valores diários da necessidade de água disponível, precipitação efetiva, irrigação, evapotranspiração máxima, irrigação, balanço hídrico em mm ao longo do ciclo do Capim-Sudão BRS Estribo, em função da semeadura simulada com data 01/10/2016 a 31/05/2017




Fonte: Autor (2018)

A seguir, serão apresentados os resultados gerados pelas simulações, levando em consideração os parâmetros do capim-sudão BRS Estribo para os anos 2007 a 2018, considerando como relevantes as seguintes variáveis: soma térmica acumulada, evapotranspiração máxima, precipitação efetiva e finalmente o parâmetro de irrigação. Deste processo se consegue simular 21786 registros, dentro dos quais 506 registros apresentam necessidade de irrigação.

Na Figura 13 é apresentada a soma térmica acumulada e aproveitada pelo capim-sudão BRS Estribo ao longo de seu ciclo. A soma térmica acumulada deve ser

interpretada como a energia aproveitada pelas plantas em Unidades Térmicas Diárias (UTD). Esta variável foi acumulada para todo o ciclo do cultivo e agrupada por ano agrícola, e os valores encontrados de soma térmica acumulada por ciclo variaram de 550 a 2707. É possível identificar pequenas variações, provavelmente devido aos efeitos gerados pelo ENSO. As sementeiras que iniciaram em outubro até dezembro resultaram em cultivos que possuíam as maiores somas térmicas. Portanto, estas sementeiras, bem manejadas, poderiam resultar em maior rendimento de forragem em termos de produção, isto devido ao fato do capim-sudão BRS Estribo ser responsivo ao fotoperíodo.

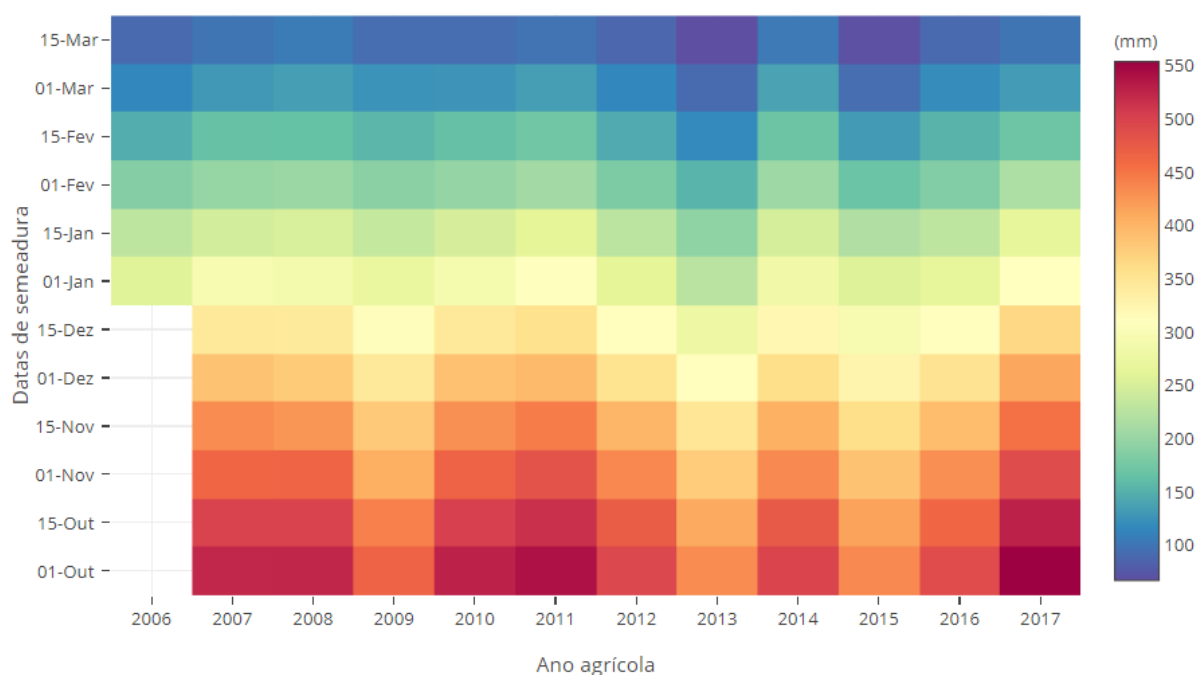
Figura 13 – Soma térmica acumulada em graus dias, acumulados em função das sementeiras, simuladas durante os anos 2007 a 2018.



Fonte: Autor (2018)

Na Figura 14 são apresentadas as simulações da evapotranspiração máxima acumulada do capim-sudão BRS Estribo ao longo de seu ciclo, que varia de 100mm até 550mm segundo a data de sementeira. Esta variável foi acumulada para todo o ciclo do cultivo e agrupada por ano agrícola. As sementeiras que iniciaram em outubro até meados de dezembro propiciaram cultivos que possuíam os maiores valores de evapotranspiração. É possível identificar variações importantes nos anos com presença do ENSO (2009, 2013 e 2015), apresentadas no Anexo 3.


Figura 14 – Evapotranspiração máxima acumulada em mm, em função das sementeiras, simuladas durante os anos 2007 a 2018.



Fonte: Autor (2018)

Foi determinada a precipitação efetiva em milímetros (mm). E esta variável deve ser interpretada como a água que ingressa de forma natural no sistema e que será aproveitada pelo capim-sudão BRS Estribo para seu desenvolvimento ao longo de seu ciclo (Figura 15). A variável foi acumulada para todo o ciclo do cultivo e agrupada para o ano agrícola. É possível identificar que esta variável possui importantes variações especialmente para os anos 2009, 2013 e 2015, onde a anomalia do ENSO apresenta as maiores variações (Anexo 3). O que traz interessantes oportunidades de manejo na produtividade, alternando entre as anomalias de *El Niño* e *La Niña*.


Figura 15 – Precipitação acumulada em mm, em função das semeaduras, simuladas durante os anos 2007 a 2018.



Fonte: Autor (2018)

Finalmente, foi determinada a irrigação acumulada em milímetros (mm). E esta variável deve ser interpretada como a água necessária que ingressa de forma artificial no sistema e que será aproveitada pelo capim-sudão BRS Estribo para seu desenvolvimento ao longo de seu ciclo, levando em consideração a necessidade de irrigação que foi ajustada ao balanço hídrico para os subperíodos do capim-sudão BRS Estribo ao longo de seu ciclo (Figura 16). Esta variável foi acumulada para todo o ciclo do cultivo e agrupada para o ano agrícola. É possível identificar que esta variável possui importantes variações especialmente para os anos 2009, 2013 e 2015, onde a anomalia do ENSO apresenta as maiores variações (Anexo 3). Estas irrigações fazem complemento à variável precipitação efetiva acumulada, anteriormente analisada. É importante mencionar que as primeiras semeaduras possuem as maiores irrigações.

Figura 16 – Irrigação acumulada em mm, em função das sementeiras, simuladas durante os anos 2007 a 2018.



Fonte: Autor (2018)

Desta maneira, pode-se calcular o parâmetro de irrigação a partir dos dados meteorológicos e parâmetros da cultura, levando em consideração o balanço hídrico a fim de dimensionar a irrigação. Esse cálculo é especialmente quando ocorrem as maiores necessidades de irrigação, visando manter a produtividade do capim-sudão BRS Estribo ao longo de seu ciclo.

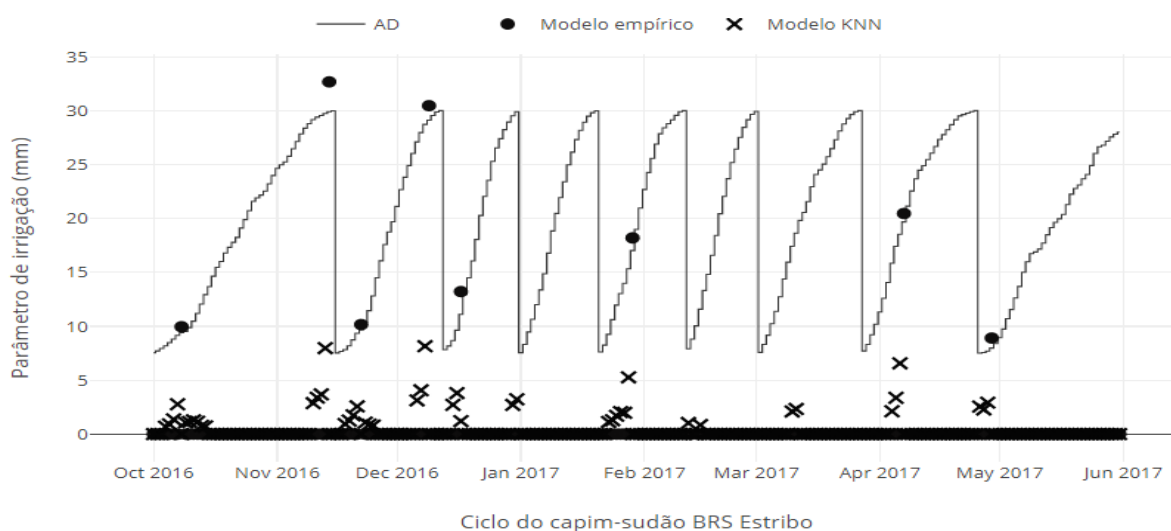
## 4.2 Resultados dos modelos de inteligência artificial

A seguir serão apresentados os resultados obtidos com os modelos de inteligência artificial. A estimativa do parâmetro de irrigação utilizada por esses modelos tem como referência o modelo empírico. Assim, os dados para os modelos de aprendizado de máquina foram integrados segundo a tarefa de pré-processamento descrita na seção 3.5.1. Deste processo se consegue 21786 registros no total, com 506 registros em dias com a necessidade de irrigação. Observe o Anexo 4 que mostra a descrição estatística das variáveis em forma de *boxplot*.

O primeiro modelo gerado foi o KNN, apresentado na Figura 17, que mostra um desempenho baixo, devido ao fato do modelo KNN ser baseado em  $k$  vizinhos mais

próximos, assim a variabilidade da ocorrência das irrigações com vizinhos mais próximos igual a zero faz com que o modelo não consiga um ótimo desempenho.

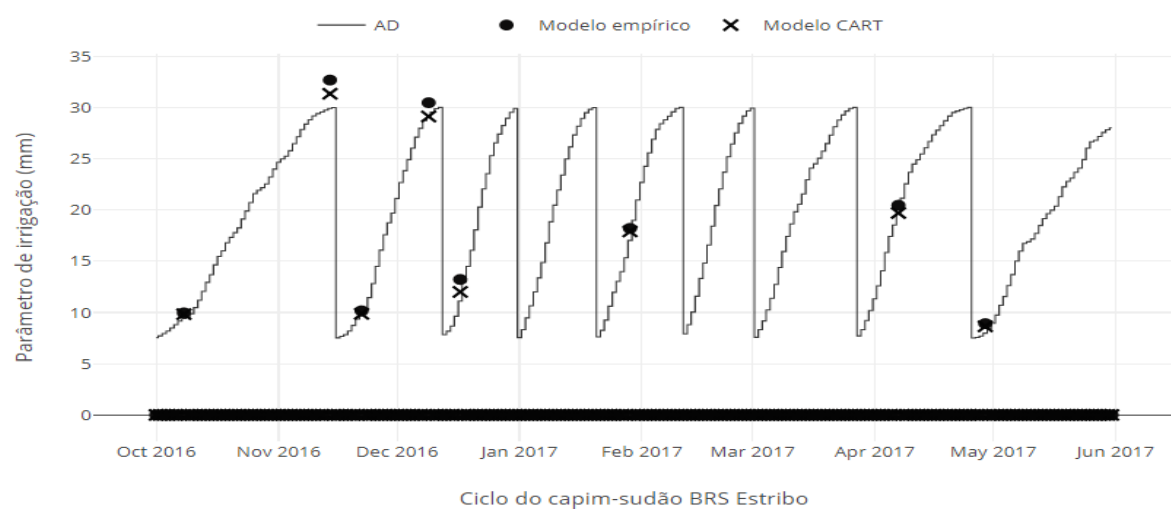
Figura 17 – Parâmetro de irrigação em mm, real e estimado pelo modelo KNN, em função da época de semeadura, simulada entre 01/10/2016 e 31/05/2017.



Fonte: Autor (2018)

O aprendizado pelo modelo CART consegue criar regras de regressão baseadas nas variáveis de maior importância. Estas regras são apresentadas no Anexo 1 e conseguem estimar o parâmetro de irrigação como é apresentada na Figura 18.

Figura 18 – Parâmetro de irrigação em mm, real e estimado pelo modelo CART, em função da época de semeadura, simulada entre 01/10/2016 e 31/05/2017.

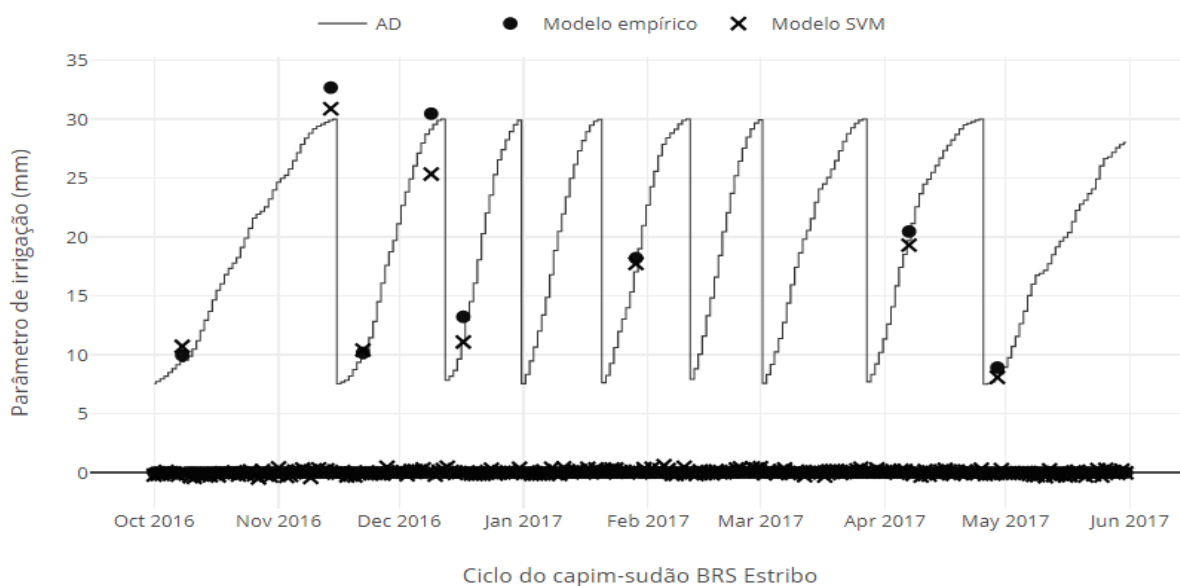


Fonte: Autor (2018)



O modelo SVM utiliza um *kernel* para mapear um espaço de características (entrada original) em um espaço de alta dimensionalidade. As fronteiras de decisão são não lineares. Posteriormente, é construído um modelo linear no espaço das características (GAO *et al.*, 2002). Esse processo permite uma melhor aproximação aos valores desejados. Por outro lado, faz com que exista uma certa variação nos valores próximos a zero (Figura 19).

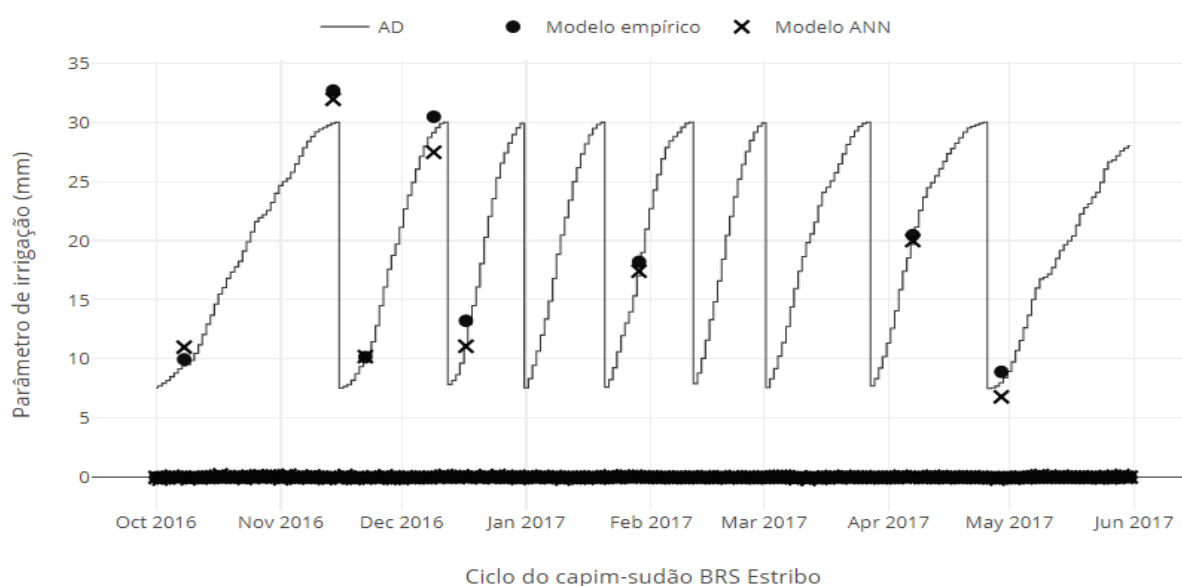
Figura 19 – Parâmetro de irrigação em mm, real e estimado pelo modelo SVM, em função da época de semeadura, simulada entre 01/10/2016 e 31/05/2017.



Fonte: Autor (2018)

Para finalizar, o modelo da ANN também apresenta uma convergência no aprendizado considerando duas camadas ocultas para poder aprender da função de descontinuidade do parâmetro de irrigação (HAYKIN, 2001). Esse processo permite uma melhor aproximação dos valores desejados, como é possível observar na Figura 20.

Figura 20 – Parâmetro de irrigação em mm, real e estimado pelo modelo ANN, em função da época de semeadura, simulada entre 01/10/2016 e 31/05/2017.



Fonte: Autor (2018)

Na Tabela 6, são apresentados os índices de rendimento para os modelos de aprendizado de máquina propostos na seção 3.5.

Tabela 6 - Índices de rendimento dos modelos de inteligência artificial

Modelo	MSE	RMSE	MAE	R <sup>2</sup>
KNN	8,900	2,983	0,672	0,078
CART	0,132	0,363	0,036	0,986
SVM	0,150	0,387	0,171	0,985
ANN	0,115	0,338	0,077	0,988

Fonte: Autor (2018)

O desempenho do modelo KNN apresenta um RMSE de 2,983 e um R<sup>2</sup> de 0,078 que são os índices de erro mais baixos comparados com os 3 modelos restantes. Uma possível explicação talvez seja que ao realizar a tarefa de aprendizagem, o número de k vizinhos considera os vizinhos mais próximos que contém o valor 0 (sem irrigação), prejudicando a estimativa por este método. Porém, isto ocorre considerando a totalidade dos registros, o seja dias com necessidade de irrigação e dias sem necessidade de irrigação. Se for considerado só dias com necessidade de irrigação o desempenho do modelo KNN tem um R<sup>2</sup> de 0.983. Porém

os resultados apresentados na Tabela 6, considera os critérios de standardização na quantidade dos registros. O desempenho do modelo CART consegue criar regras de regressão baseadas nas variáveis de maior importância. Estas regras de regressão (Anexo 1) conseguem estimar o parâmetro de irrigação próximo aos valores desejados com um RMSE de 0,387, um  $R^2$  de 0,986 e um MAE de 0,036, tendo este último índice um valor baixo porque as regras não consideram valores inferiores a 0 como parâmetro de irrigação. De forma similar, SVM consegue uma alta aproximação aos valores desejados com um RMSE de 0,387 e um  $R^2$  de 0,985 do modelo final. Finalmente, o modelo ANN apresenta um RMSE de 0,338 e um  $R^2$  de 0,988, mostrando uma convergência no aprendizado, o qual representa que a estimação do modelo é próxima aos valores desejados e propostos pelo especialista.

É interessante observar que grande parte do aprendizado ocorre ao incluir a variável soma térmica acumulada. No modelo empírico, esta variável tem correlação direta com o desenvolvimento do capim-sudão BRS Estribo ao longo do ciclo. Este comportamento fenológico, que responde ao desenvolvimento do cultivo, também poderia responder à necessidade de irrigação. Também se observa que o ajuste fino ocorre com as variáveis de evapotranspiração acumulada e temperatura mínima.

### 4.3 Avaliação do desempenho dos modelos

Após analisar os índices de regressão obtidos pelos modelos de inteligência artificial, foram avaliados estatisticamente o desempenho com base no índice “c” proposto por Camargo & Sentelhas (1997). É importante ter em conta que no cálculo do parâmetro de irrigação pelo método empírico, as equações empregadas estão baseadas em grande parte na soma térmica e na disponibilidade hídrica, que as limita a serem usadas para locais com as mesmas condições onde foi efetuada sua determinação. Deste modo, embora algumas dessas equações sejam frequentemente citadas na literatura, é importante uma análise de desempenho que integre os índices de rendimento dos modelos de inteligência artificial.

Devido ao fato de ser apresentado mais de um modelo de estimativa para o parâmetro de irrigação, foi importante ter um indicador, neste caso o índice “c” (Tabela 7), a fim de ter um critério de comparação de desempenho dos modelos na tarefa de estimativa do parâmetro de irrigação. Portanto, a Tabela 7 apresenta o desempenho dos 4 modelos de inteligência artificial pelo índice “c”. Com base nos índices “c”, os

modelos CART, SVM e ANN se apresentam como ótimas opções na tarefa da estimativa do parâmetro de irrigação para o capim-sudão BRS Estribo ao longo de seu ciclo.


Tabela 7 - Desempenho dos modelos de inteligência artificial pelo índice “c”

Modelo	Índice “c”	Desempenho
KNN	0,02	Péssimo
CART	0,93	Ótimo
SVM	0,93	Ótimo
ANN	0,94	Ótimo

Fonte: Autor (2018)

Do mesmo modo, a Figura 21 mostra o desempenho dos modelos de inteligência artificial na estimativa do parâmetro de irrigação com base nos indicadores estatísticos de Camargo & Sentelhas (1997), em que a precisão é dada pelo coeficiente de correlação “r”, a exatidão representada pelo índice de Willmott “d” e a confiança ou desempenho pelo índice “c”. O modelo ANN mostrou ótimo desempenho, muito próximo aos valores dos modelos SVM e CART. Contrariamente o modelo KNN mostrou-se péssimo segundo o índice “c”. Os índices de desempenho dos modelos pelo índice “c” apresentam semelhança aos índices de rendimento dos modelos de inteligência artificial, devido provavelmente ao fato dos resultados dos modelos CART, SVM e ANN estarem próximos aos valores reais. A dispersão dos valores do parâmetro de irrigação estão delimitadas pela linha 1:1 (diagonal principal). A diagonal principal separa os valores do parâmetros de irrigação em valores subestimados (elementos abaixo da diagonal) e valores sobrestimados (elementos acima da diagonal).

Figura 21 – Dispersão do parâmetro de irrigação pelos modelos de KNN, CART, SVM, ANN em relação ao modelo empírico.



Fonte: Autor (2018)

## 5 CONSIDERAÇÕES FINAIS

O objetivo deste trabalho foi modelar o parâmetro de irrigação para o capim-sudão BRS Estribo. Para que este objetivo fosse atingido, foram abordados modelos empíricos e modelos de inteligência artificial com foco no aprendizado de máquina supervisionado. A elaboração do modelo empírico foi implementada através de um protótipo que simula os parâmetros de irrigação ao longo do ciclo do capim-sudão BRS Estribo.

Os experimentos realizados mostraram que este método usando os dados meteorológicos e parâmetros do cultivo, permitem modelar empiricamente o parâmetro de irrigação. Este modelo empírico tem potencial de poder responder à necessidade hídrica para os cultivos, tendo como diferencial o fato de calcular o parâmetro de irrigação ao longo do ciclo do capim-sudão BRS Estribo, a partir de uma data de semeadura, mantendo um registro histórico do parâmetro cultivo.

Portanto, para fazer frente aos problemas de deficiências hídricas é necessário uma avaliação acurada do potencial hídrico. O método que melhor se adequa para quantificar este potencial é o modelo empírico baseado no balanço hídrico, porque é possível a integração das características solo-água-planta-atmosfera no potencial hídrico, levando em consideração a integração destas características em uma serie temporal e histórica.

A abordagem dos modelos de inteligência artificial, por outro lado, não está condicionada a um registro histórico do balanço hídrico. O aprendizado dos modelos CART, SVM e ANN está baseado na extração do comportamento dos dados. Este processo permite modelar e generalizar o aprendizado e, por conseguinte, estimar o parâmetro de irrigação para o capim-sudão BRS Estribo. Escolher os parâmetros ótimos para os modelos é um passo importante na etapa do aprendizado. A validação cruzada *k-fold* é uma forma confiável de determinar os hiperparâmetros ótimos. Portanto os modelos finais de inteligência artificial são obtidos depois do treinamento, utilizando estes hiperparâmetros ótimos. Os modelos obtidos nesse processo podem ter propriedades de generalização do parâmetro de irrigação para o capim-sudão BRS Estribo. Esses modelos poderiam ser considerados na aplicação prática no processo de irrigação, consequentemente no planejamento dos recursos hídricos.

Finalmente, o impacto da aplicação dos modelos de inteligência artificial no setor agropecuário poderia criar interessantes oportunidades, levando em

consideração a tecnologia, o Big Data e modelos de inteligência artificial que possam dar suporte a estes tipos de enfoque.

Propõe-se como trabalhos futuros a integração do modelo empírico na ferramenta Orange, do mesmo modo uma versão web do modelo empírico a fim de levar o balanço hídrico proposto a partir de uma data de semeadura.

Propõe-se também a possibilidade de extrapolar o modelo para outras culturas, seguindo a metodologia baseada em dados meteorológicos e parâmetros da cultura.

## REFERÊNCIAS

- ABIEC. Perfil da Pecuária no Brasil - **Relatório Anual. abiec**, 2018. Disponível em: <<http://abiec.siteoficial.ws/images/upload/sumario-pt-010217.pdf>>. Acesso em: 11 nov. 2018.
- AGÊNCIA NACIONAL De ÁGUAS (ANA). **Atlas irrigação: uso da água na agricultura irrigada**. Brasília: Ana, 2017. 86 p. Disponível em: <<http://atlasirrigacao.ana.gov.br>>. Acesso em: 11 nov. 2018.
- AGUIRRE-SALADO, C. A. *et al.* Mapeo del índice de área foliar y cobertura arbórea mediante fotografía hemisférica y datos SPOT 5 HRG: regresión y k-nn. **Agrociencia**, v. 45, n. 1, p. 105-119, 2011.
- ALLEN, R. G. *et al.* **Evapotranspiración del cultivo. Guía para la determinación de los requerimientos de agua de los cultivos**, 300pp., Estudio FAO Riego y Drenaje 56. ISBN 92-5-304219-2, ISSN 0254-5293, Rome, 2006. Disponível em: <<http://www.fao.org/3/a-x0490s.pdf>>. Acesso em: 11 nov. 2018.
- ALTMAN, N. S. An introduction to kernel and nearest-neighbor nonparametric regression. **The American Statistician**, v. 46, n. 3, Aug 1992. p. 175-185.
- ARNOLD, C.Y. *et al.* Maximum-minimum temperatures as a basis for computing heat units. **American Society for Horticultural Science**, Boston v.76, 1960. p. 682-692.
- ÁVILA, A. M. H. de *et al.* Probabilidade de ocorrência de precipitação pluvial mensal igual ou maior que a evapotranspiração potencial para a estação de crescimento das culturas de primavera-verão no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Gaúcha, Porto Alegre**, v. 2, n. 2, p. 149-154, 1996.
- BERLATO, M. A.; FARENZENA, H.; FONTANA, D. C. Associação entre El Niño Oscilação Sul e a produtividade do milho no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, v. 40, n. 5, p. 423-432, 2005.
- BIRANT, D.; KUT, A. ST-DBSCAN: An algorithm for clustering spatial-temporal data. **Data & Knowledge Engineering**, v. 60, n. 1, p. 208-221, 2007.
- BRAGA, A. de P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro, Brazil: Livros Técnicos e Científicos, 2000. 248 p.
- BRUNINI, O. *et al.* Temperatura-base para alface cultivar "White Boston", em um sistema de unidades térmicas. **Bragantia**, v. 35, n. 1, 1976. p. 213-219.
- CAMARGO, A. P. de; SENTELHAS, P. C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de agrometeorologia**, Santa Maria, v. 5, n. 1, p. 89-97, 1997.



CAVIGLIONE, J. H. *et al.* **Cartas climáticas do Estado do Paraná**. Londrina: IAPAR, v. 1, 2000.

DEMŠAR, J. *et al.* Orange: data mining toolbox in Python. **The Journal of Machine Learning Research**, v. 14, n. 1, p. 2349-2353, 2013.

DOURADO-NETO, D. *et al.* Balance hídrico cíclico y secuencial: estimación de almacenamiento de água en el suelo. **Scientia Agrícola**, Piracicaba, v. 56, n. 3, 1999. p. 537-546.

DRUCKER, H. *et al.* Support vector regression machines. In: **Advances in neural information processing systems**. 1997. p. 155-161.

DRUMOND, L. C. D.; AGUIAR, A. P. A. **Irrigação de pastagem**. Uberaba: LCD Drumond, 2005.

EMBRAPA. **Impacto bioeconômico do capim-sudão BRS Estribo na produção de bovinos de corte**. 2017. (18m31s). Disponível em: <<https://youtu.be/noXoQ1fIRyM>>. Acesso em: 11 nov. 2018.

EMBRAPA. Saiba manejar o novo capim-sudão BRS Estribo. **Revista do Produtor**, Bagé, v. 7, n. 6, mar. 2014. p.18-19.

ELNESR, M. N.; ALAZBA, A. A. Simulation of water distribution under surface dripper using artificial neural networks. **Computers and Electronics in Agriculture**, v. 143, p. 90-99, 2017.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. The KDD process for extracting useful knowledge from volumes of data. **Communications of the ACM**, v. 39, n. 11, p. 27-34, 1996.

FERERES, E.; SORIANO, M. A. Deficit irrigation for reducing agricultural water use. **Journal of experimental botany**, v. 58, n. 2, p. 147-159, 2006.

FRIEDMAN, J.; HASTIE, T.; TIBSHIRANI, R. **The elements of statistical learning: data mining, inference, and prediction**. 2. ed. California: New York, NY: Springer, 2009. 745 p.

FRIZZONE, J. A. *et al.* **Planejamento de irrigação: análise de decisão de investimento**. Brasília: Embrapa Informação Tecnológica, 2005. 626 p.

GAO, J. B. *et al.* A probabilistic framework for SVM regression and error bar estimation. **Machine Learning**, v. 46, n. 1-3, p. 71-89, 2002.

GÉRON, A. **Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems**. California: O'reilly Media, 2017. 574 p.

GIL, A. C. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2007. 192 p.

GILMORE, E. C.; ROGERS, J. S. Heat units as a method of measuring maturity in corn 1. **Agronomy Journal**, v. 50, n. 10, p. 611-615, 1958.

GOAP, A. *et al.* An IoT based smart irrigation management system using Machine learning and open source technologies. **Computers and Electronics in Agriculture**, v. 155, p. 41-49, 2018.

GUZMÁN-CRUZ, R. *et al.* Calibration of a greenhouse climate model using evolutionary algorithms. **Biosystems engineering**, v. 104, n. 1, p. 135-142, 2009.

HAIM, S. **Response modeling methodology**: empirical modeling for engineering and science. Massachusetts: World Scientific Publishing Co, 2005. 460 p. (Vol. 8).

HASSAN-ESFAHANI, L.; TORRES-RUA, A.; MCKEE, M. Assessment of optimal irrigation water allocation for pressurized irrigation system using water balance approach, learning machines, and remotely sensed data. **Agricultural Water Management**, v. 153, p. 42-50, 2015.

HAYKIN, S. **Redes Neurais**: Princípios e Prática. 2. ed. Porto Alegre, RS, Brazil: Bookman Editora, 2001. 898 p.

HERRERO, J. M. *et al.* Robust identification of non-linear greenhouse model using evolutionary algorithms. **Control Engineering Practice**, v. 16, n. 5, p. 515-530, 2008.

HOLLAND, J. H. **Adaptation in natural and artificial systems**: an introductory analysis with applications to biology, control, and artificial intelligence. USA: MIT Press, 1992. 228 p.

HU, Y. *et al.* Combining human and machine intelligence to derive agents' behavioral rules for groundwater irrigation. **Advances in Water Resources**, v. 109, p. 29-40, 2017.

INFORMATIVO NESPRO & EMBRAPA PECUÁRIA SUL: **Bovinocultura de Corte no Rio Grande do Sul**. Ano 4, n. 1, Porto Alegre, RS: UFRGS, 2018 – Semestral.

JAAFARI, A.; ZENNER, E. K.; PHAM, B. T. Wildfire spatial pattern analysis in the Zagros Mountains, Iran: A comparative study of decision tree based classifiers. **Ecological Informatics**, v. 43, p. 200-211, 2018.

LIMA, J. E. F. W. **Recursos hídricos no Brasil e no mundo**. Planaltina: Embrapa Cerrados, 2001. 44 p.

LIMA, J. E. F. W.; FERREIRA, R. S. A.; CHRISTOFIDIS, D. **O uso da irrigação no Brasil**: O estado das águas no Brasil. Brasília: Agência Nacional de Energia Elétrica. 1999. Disponível em: <[https://www.agencia.cnptia.embrapa.br/Repositorio/irrigacao\\_000fl7vsa7f02wyiv80isprr5frxoq4.pdf](https://www.agencia.cnptia.embrapa.br/Repositorio/irrigacao_000fl7vsa7f02wyiv80isprr5frxoq4.pdf)>. Acesso em: 11 nov. 2018.

LUGER, G. F. **Inteligência artificial**. 6. ed. São Paulo: Pearson Education do Brasil, 2004. 632 p.

KÖRNER, C.; HILTBRUNNER, E. The 90 ways to describe plant temperature. **Perspectives in Plant Ecology, Evolution and Systematics**, [s.l.], v. 30, p.16-21, 2018.

MALCORRA, M. P. *et al.* Determinação do intervalo entre cortes para o capim sudão utilizando a somatémica. In: Embrapa Pecuária Sul-Artigo em anais de congresso (ALICE). In: CONGRESSO DE INICIAÇÃO CIENTÍFICA, 26. ENCONTRO DE PÓS-GRADUAÇÃO UFPEL, 19. SEMANA INTEGRADA DE ENSINO, PESQUISA E EXTENSÃO, 3. **Anais**. Pelotas: UFPel, 2017. Disponível em: <[http://cti.ufpel.edu.br/siepe/arquivos/2017/CA\\_02317.pdf](http://cti.ufpel.edu.br/siepe/arquivos/2017/CA_02317.pdf)>. Acesso em: 11 nov. 2018.

MEDRANO, H. *et al.* Eficiencia en el uso del agua por las plantas. **Investigaciones Geográficas** (Esp), Alicante, n. 43, p. 63-84, 2007. Disponível em: <<https://www.redalyc.org/html/176/17604304>>. Acesso em: 11 nov. 2018.

MOHAPATRA, A. G.; LENKA, S. K. Neural network pattern classification and weather dependent fuzzy logic model for irrigation control in WSN based precision agriculture. **Procedia Computer Science**, v. 78, p. 499-506, 2016.

NIED, A. H. **Balanço hídrico diário do solo simulado para diferentes épocas de semeadura do milho em Santa Maria, RS**. 2003. 91f. Dissertação (Mestrado em Agronomia) – Universidade Federal de Santa Maria, 2003.

OLSON, D. L.; WU, D. **Predictive Data Mining Models (Computational Risk Management)**. Singapore: Springer, 2017. 116 p.

PEREIRA, A. R.; VILLA-NOVA, N. A.; SEDIYAMA, G. C. **Evapotranspiração**. Piracicaba: FEALQ, 1997. 183 p.

QUINLAN, J. R. Induction of decision trees. **Machine learning**, v. 1, n. 1, 1986. p. 81-106.

RASCHKA, S.; MIRJALILI, V. **Python Machine Learning**. 2. ed. Birmingham, Uk: Packt Publishing, 2017. 622 p.

ROMERO, A. L.; GRAÑA, R. C. Modelos para el cálculo de la lluvia efectiva y su aplicación en caña de azúcar. **Caña de Azúcar**, v. 17, p. 3-20, 1999.

ROMERO, M. *et al.* Vineyard water status estimation using multispectral imagery from an UAV platform and machine learning algorithms for irrigation scheduling management. **Computers and Electronics in Agriculture**, v. 147, p. 109-117, 2018.

ROGEL-SALAZAR, J. **Data Science and Analytics with Python (Chapman & Hall/CRC Data Mining and Knowledge Discovery Series)**. Minnesota, USA: Chapman and Hall/CRC, 2018. 400 p.

ROSENBLATT, F. **Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms**. Washington D.c: Spartan Books, 1959. 616 p.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning internal representations by error propagation**. California Univ San Diego La Jolla Inst for Cognitive Science, 1986.

SACCON, P. Water for agriculture, irrigation management. **Applied Soil Ecology**, v. 123, p. 793-796, 2018.

SBRISSIA, A. F.; SILVA, S. D. O ecossistema de pastagens e a produção animal. **Reunião Anual da Sociedade Brasileira de Zootecnia**, v. 38, p. 731-754, 2001.

SILVA, C. L. A. *et al.* Modelagem da precipitação efetiva na cultura do milho. **Pesquisa Agropecuária Brasileira**, v. 29, n. 6, p. 929-937, 1994.

SILVEIRA, M. C. T. D. *et al.* **Aspectos Relativos à Implantação e Manejo de Capim-Sudão BRS Estribo. Comunicado Técnico 89**. Bagé, Brasil: Embrapa Pecuária Sul, 2015. 11 p.

TANAKA, A.; DIAGNE, M.; SAITO, K. Causes of yield stagnation in irrigated lowland rice systems in the Senegal River Valley: application of dichotomous decision tree analysis. **Field Crops Research**, v. 176, p. 99-107, 2015.

THORNTHWAITE, C. W.; MATHER, J. R. The water balance. **Publications in Climatology**, [S.L.], v. 3, n. 10, 1955. 104 p.

TRAORE, S.; WANG, Y. M.; KERH, T. Artificial neural network for modeling reference evapotranspiration complex process in Sudano-Sahelian zone. **Agricultural water management**, v. 97, n. 5, p. 707-714, 2010.

TRENTIN, G. *et al.* Produção de matéria verde e seca de capim-sudão BRS Estribo submetido a diferentes disponibilidades hídricas. In: Embrapa Pecuária Sul-Artigo em anais de congresso (ALICE). In: CONGRESSO BRASILEIRO DE ZOOTECNIA, 26, 2016, Santa Maria. Cinquenta anos de zootecnia no Brasil: **Anais**. Santa Maria: Sociedade Brasileira de Zootecnia, 2016.

SILVA, J. C. D. **Parâmetros de irrigação para o feijoeiro em diferentes solos e épocas de semeadura na região central do Rio Grande do Sul**. 2008. 112f. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Santa Maria, Santa Maria, 2008.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on Support Vector Regression. **Statistics and computing**, v. 14, n. 3, p. 199-222, 2004.

WILLMOTT, C. J. *et al.* Statistics for the evaluation and comparison of models. **Journal of Geophysical Research: Oceans**, v. 90, n. C5, p. 8995-9005, 1985.

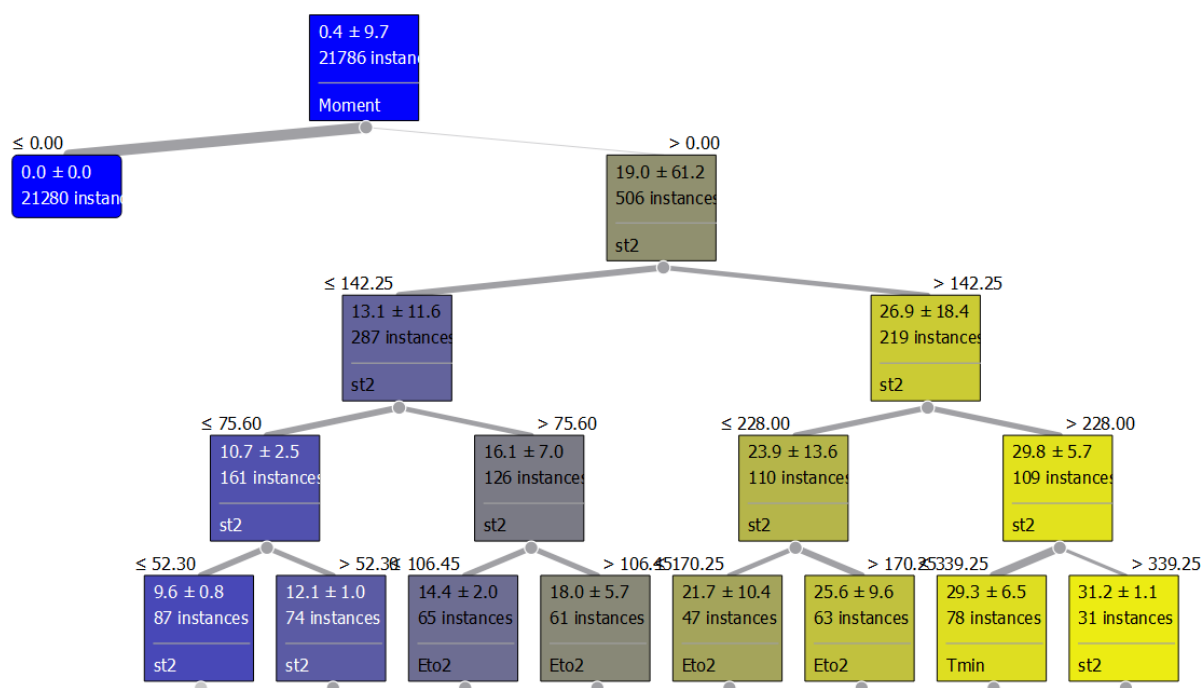
WITTEN, I. H. *et al.* **Data Mining: Practical Machine Learning Tools and Techniques**. 4. ed. Cambridge: Morgan Kaufmann, 2016. 654 p.

WREGGE, M. S. *et al.* **Atlas climático da Região Sul do Brasil: Estados do Paraná, Santa Catarina e Rio Grande do Sul**. 2. ed. Pelotas: Embrapa Clima Temperado, 2012. 333 p. Disponível em: <<http://ainfo.cnptia.embrapa.br/digital/bitstream/item/143521/1/Atlas-climatico-da-regiao-Sul-do-Brasil.pdf>>. Acesso em: 30 mar. 2018.

# ANEXO

## Anexo 1

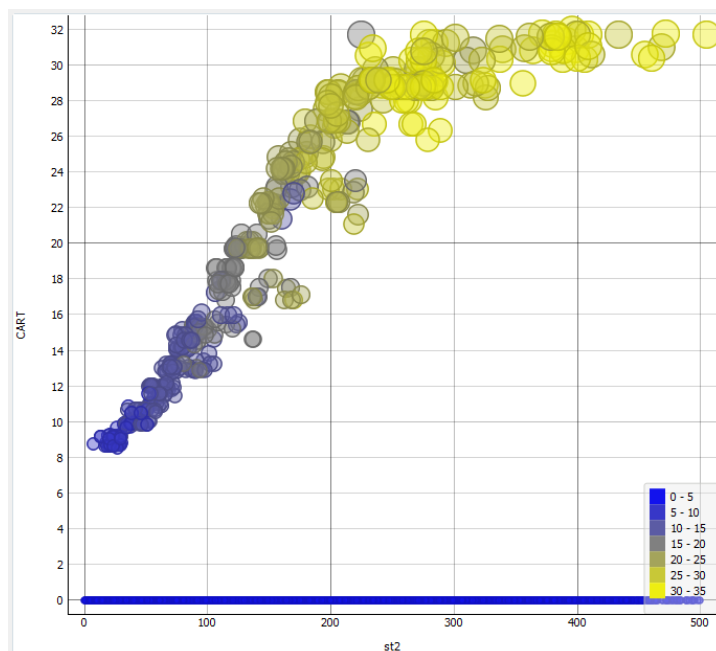
Regras geradas pelo modelo CART para a estimação do parâmetro de irrigação, para as variáveis da Estação Meteorológica Principal da Embrapa Pecuária Sul, Bagé - RS, para o período de janeiro de 2007 a maio de 2018.



Fonte: Autor (2018)


## Anexo 2

Parâmetro de irrigação pelo modelo CART, levando em consideração a soma térmica acumulada da Estação Meteorológica Principal da Embrapa Pecuária Sul, Bagé - RS, para o período de janeiro de 2007 a maio de 2018.



Fonte: Autor (2018)


Parâmetro de irrigação pelo modelo KNN, levando em consideração a soma térmica acumulada da Estação Meteorológica Principal da Embrapa Pecuária Sul, Bagé - RS, para o período de janeiro de 2007 a maio de 2018.



Fonte: Autor (2018)




Parâmetro de irrigação pelo modelo SVM, levando em consideração a soma térmica acumulada da Estação Meteorológica Principal da Embrapa Pecuária Sul, Bagé - RS, para o período de janeiro de 2007 a maio de 2018.





Fonte: Autor (2018)

Parâmetro de irrigação pelo modelo ANN, levando em consideração a soma térmica acumulada da Estação Meteorológica Principal da Embrapa Pecuária Sul, Bagé - RS, para o período de janeiro de 2007 a maio de 2018.



Fonte: Autor (2018)


Anexo 3




El Niño ↑  
 Neutral →  
 La Niña ↓

#### Anexo 4


Temperaturas máximas - Ano agrícola (2007 a 2018)




Temperaturas mínimas - Ano agrícola (2007 a 2018)




Evapotranspiração de referência - Ano agrícola (2007 a 2018)



Soma térmica do capim-sudão BRS Estribo - Ano agrícola (2007 a 2018)



ENSO - Ano agrícola (2007 a 2018)



Irrigação - Ano agrícola (2007 a 2018)

