

TouceiraTech: uma proposta de FMIS inovador para predição de disponibilidade de pasto e ajuste de lotação animal

Ânderson Fiscoeder Soares¹[0000-0002-8367-6756],
Naylor Bastiani Perez^{1,2}[0000-0002-4667-783X], and
Leonardo Bidese de Pinho¹[0000-0003-1198-989X]

¹ Universidade Federal do Pampa - Unipampa

² Empresa Brasileira de Pesquisa Agropecuária - Embrapa

Resumo Para aumentar a produtividade em sistemas de produção de animais a pasto, com baixo custo e sem degradação do ambiente, é necessário ajustar a lotação animal à disponibilidade de alimento. Convencionalmente, o ajuste de lotação é realizado com base na taxa de acúmulo do período anterior, sem considerar as variações meteorológicas diárias observadas desde a última estimativa. O presente trabalho apresenta os princípios e resultados preliminares de um Farm Management Information System (FMIS), denominado TouceiraTech, concebido para a predição da disponibilidade de forragem em pastagens naturais por meio de Inteligência Artificial. O modelo correlaciona dados meteorológicos obtidos automaticamente, de bases remotas abertas, com dados históricos da pastagem, obtidos por amostragem estratificada em áreas experimentais do Bioma Pampa. O sistema inova em funcionalidades desenvolvidas na Linguagem Python permitindo coletar automaticamente os dados históricos de experimentos e da previsão meteorológica recente, bem como calcular a evapotranspiração. As informações, armazenadas em um banco de dados espacial, contemplam as variáveis de entrada necessárias ao modelo de predição de matéria seca (MS) de pasto, proposto em trabalho anterior, baseado em uma rede neural convolucional do tipo Long Short-Term Memory (LSTM). Os resultados evidenciam que a inclusão do cálculo automático da evapotranspiração, com auxílio do Pacote PyEto, apresenta uma acurácia adequada em comparação com o processo manual anteriormente adotado, sendo também verificada a capacidade do sistema para obter e processar os dados de previsão meteorológica de diferentes órgãos, predizendo com diferentes níveis de acurácia a oferta de MS com horizonte de quinze dias.

Keywords: Ajuste do pastejo · Sistemas de apoio à decisão · Métodos de amostragem · Agrometeorologia · Modelo de predição de massa de forragem

1 Introdução

Devido ao crescimento populacional do mundo que, segundo a Organização das Nações Unidas, aumentaria em mais de 30% até 2050. O Brasil ocupa uma posição de destaque no cenário mundial para o fornecimento de alimentos seguros e nutritivos, especialmente no que se refere à proteína animal [1]. Para que o aumento na produção bovina seja sustentável, um fator muito importante foi a adoção de tecnologias tais como, suplementação estratégica de alimentos, semiconfinamento e manejo das pastagens, sendo essa última tecnologia a mais sustentável e que acarreta em menos gastos com alimentação dos animais. Para que seja possível aumentar a produtividade e reduzir os gastos com alimentação, surge o conceito de Pecuária Sustentável que tem por objetivo realizar o adequado manejo das pastagens, ou seja, garantir a qualidade e a quantidade necessária para a alimentação dos animais, sem a degradação das pastagens [18]. Um fator que auxiliou a pecuária de corte a se tornar protagonista no agronegócio brasileiro foi a incorporação de gestão tecnológica integrada aos custos e às margens econômicas [28]. Quando se trata de custos de produção animal, o gasto necessário para alimentação animal está entre 50% a 80% [21]. Porém, o correto uso das pastagens, além de amenizar o gasto com alimentação, impulsiona a produtividade do rebanho já que, no contexto da pecuária, a produtividade é representada pelo peso vivo produzido anualmente por hectare de pastagem [11].

As Tecnologias da Informação e da Comunicação voltadas ao agronegócio (AgroTIC), podem ser usadas para auxiliar no contexto da pecuária para armazenamento de informações acerca de condições sanitárias, nutricionais e genéticas dos animais [16]. Contudo, desde 1997 se destaca que “inúmeras são as aplicações do uso das tecnologias da informação na bovinocultura, sendo a mais importante delas o desenvolvimento de sistemas computacionais que buscam auxiliar produtores e profissionais na tomada de decisão” [15]. Em particular, com a necessidade de aprimorar o método amostral utilizado, foi desenvolvido um modelo de predição baseado em aprendizagem de máquina [22,23], o qual correlaciona os dados históricos de corte obtidos pela unidade da Empresa Brasileira de Pesquisa Agropecuária (Embrapa), localizada em Bagé-RS, com o impacto de variáveis meteorológicas no crescimento das pastagens. Entre estas variáveis está a evapotranspiração referencial (ET_o), também chamada de potencial, que pode ser caracterizada como a perda de água do solo para a atmosfera, em unidade de tempo. A ET_o, assim como a chuva, é expressa em milímetros pluviométricos [3].

A partir deste contexto, o presente trabalho buscou estudar e desenvolver, a partir de princípios de AgroTIC, um sistema de apoio à decisão baseado em FMIS que possa realizar a predição de disponibilidade de forragem em uma determinada área, aprimorando os seguintes pontos, caracterizados como objetivos essenciais, do modelo anteriormente desenvolvido [22,23]:

- (i) coleta automática dos dados meteorológicos;
- (ii) automatização do cálculo da evapotranspiração; e
- (iii) incorporação de um módulo automatizado de busca de dados de previsão meteorológica, permitindo a predição futura da oferta de matéria seca.

2 Revisão Bibliográfica

O presente trabalho é considerado interdisciplinar, abrangendo pesquisas sobre questões referentes a Pecuária de Precisão e sobre alternativas da área de computação para solucionar o problema. As subseções a seguir apresentam as temáticas e tecnologias estudadas na pesquisa.

2.1 Desafios de gestão da pastagem

Para o Beef Cattle Research Council (BCRC), a pastagem “é um recurso crítico na indústria de gado” [6]. Segundo o BCRC, inovações na gestão da pastagem permitem que produtores gerenciem de forma combinada o ecossistema da pastagem com o seu uso para a produção de alimento. Contudo, a avaliação de massa de forragem (MF) deve ser precisa para um adequado manejo da pastagem. A MF é um importante parâmetro para a eficácia no gerenciamento para tomada de decisão na produção animal [9]. A estimativa de MF é fundamental, pois também nos permite calcular a taxa de lotação, estimar a quantidade de forragem consumida e interpretar o rendimento da produtividade animal [10].

As técnicas para a estimativa de MF, normalmente expressas em kg/ha de matéria seca (MS), podem ser classificadas como diretas e indiretas. Os métodos diretos baseiam-se no corte e remoção da pastagem, podendo ser em uma área amostral ou área total onde está sendo realizada a avaliação. Já os métodos indiretos são não destrutivos, minimizam a remoção da pastagem e diminuem o tempo de coleta e processamento dos dados [8].

2.2 TIC aplicáveis à Agropecuária

Modificações nos processos de desenvolvimento, e suas consequências na democracia e cidadania, convergem para uma sociedade caracterizada pela importância crescente dos recursos tecnológicos e pelo avanço das Tecnologias de Informação e Comunicação (TIC) com impacto nas relações sociais, empresariais e nas instituições [17]. Com o passar dos anos surgiram as TIC voltadas para a agropecuária, denominadas AgroTIC, definidas como “a combinação de hardware, software e instrumentos de produção que permitam coleta, armazenamento, troca, processamento e manejo da informação e do conhecimento” [17].

À medida que máquinas inteligentes e sensores surgem em fazendas e dados de fazenda crescem em quantidade, processos agrícolas tornam-se cada vez mais orientados a dados e ativados por dados [29]. Com isso, surge o conceito de Smart Farming que visa capacitar os agricultores com as ferramentas de decisão e as tecnologias de automação que integram perfeitamente produtos, conhecimento e serviços para melhor produtividade, qualidade e lucro [14]. Smart Farming explora as limitações da agricultura tradicional por meio de monitoramento em tempo real, minimização da mão-de-obra, tempo, estimativa precisa da água necessária para irrigação e protege a colheita de desastres como doenças [20].

2.3 Farm Management Information Systems

Um Farm Management Information System (FMIS) é definido como um sistema planejado para a coleta, processamento, armazenamento e disseminação de dados na forma de informações necessárias para executar as funções operacionais da fazenda [24]. Componentes essenciais dos FMIS incluem projetos específicos orientados ao agricultor, interfaces de usuário dedicadas, funções automatizadas de processamento de dados, conhecimento especializado e preferências do usuário, comunicação de dados padronizada e escalabilidade [19]. O ambiente tornou-se complexo devido às novas preocupações em relação ao processo produtivo de uma propriedade. As estruturas agrícolas se tornaram mais complexas devido ao aumento das extensões das mesmas, porém, sem redução substancial das áreas cultivadas, conseqüentemente a complexidade da gestão aumentou. O terceiro fator está na adoção de novas tecnologias ao ambiente agrícola, visto que muitos produtores introduziram softwares para coleta, armazenamento e processamentos dos dados, máquinas acionadas por Global Navigation Satellite System (GNSS) e aplicações que utilizam Sistema de Informações Geográficas (SIG).

Com o advento de novas tecnologias, como por exemplo, banco de dados, Data Warehouses, Bibliotecas Virtuais, etc. e também com o preço do hardware cada vez mais baixo, o volume de dados produzido é cada vez maior. Porém a problemática deixou de ser em relação ao armazenamento dos dados e sim o que fazer com os dados produzidos [4]. Na busca por informações importantes existentes nos dados, a Mineração de Dados é uma técnica muito eficaz para extrair conhecimento a partir de um grande volume de dados. A partir disso é possível estabelecer relações e padrões entre os dados, com isso, é possível auxiliar na tomada de decisão [13].

No contexto de armazenamento, existem os chamados Bancos de Dados (BD) que podem ser definidos como um conjunto de dados armazenados, permanecendo salvos em seus locais depois que o trabalho que os utilizava for encerrado e o computador desligado e que possam ser manipulados a qualquer tempo [26]. A definição de um banco de dados consiste na especificação dos tipos de dados, restrições e estruturas. A construção é o processo de armazenar os dados em alguma mídia capaz de ser controlada pelo Sistema Gerenciador de BD (SGBD).

O aprendizado de máquina pode ser definido como uma subárea da Inteligência Artificial (IA), que pesquisa métodos computacionais que visam a aquisição automática de novos conhecimentos, habilidades e formas de organizar o conhecimento já adquirido [2]. As técnicas de aprendizado de máquina existentes são aprendizado supervisionado e não supervisionado. Em supervisionado é fornecido um conjunto de dados de treinamento formado pelas entradas e saídas desejadas, assim como foi desenvolvido o modelo de predição do presente trabalho. Já em não supervisionado apenas os atributos de entrada estão disponíveis, ou seja, não contém pares de entradas-saídas desejadas e sem indicações sobre a adequação das saídas produzidas [25].

2.4 Trabalhos Correlatos

A partir da revisão sistemática, seguindo os passos de definição de palavras-chave, definição de bases de busca, tais como: Scielo, IEEE Xplore e Science-Direct, criação de uma *string* de busca e definição de critérios de inclusão e exclusão, foram encontrados os trabalhos apresentados em ordem cronológica na Tabela 1.

Tabela 1. Trabalhos correlatos encontrados a partir de revisão sistemática.

| Autores | Região | Pastagem | Modelo |
|---------|--------|------------|---|
| [12] | S | Nativa | Agrometeorológico-espectral com ETM+/Landsat 7 |
| [27] | SE-CO | Não Nativa | Sistema Invernada e CROPGRO |
| [7] | SE | Não Nativa | Regressão linear simples e múltipla |
| [5] | S | Não Nativa | Loomis e Williams, Sinclair, Doorimbos e Kassam |
| [22] | S | Nativa | CNN LSTM |

Em 2007, [12] apresentou um método capaz de estimar a disponibilidade de forragem através da parametrização do submodelo espectral do modelo JONG. Foram coletadas amostras em campo na mesma data em que o satélite ETM+/Landsat 7 passava pela área experimental. Antes da parametrização, foram realizadas operações nas imagens com o intuito de reduzir os efeitos atmosféricos sobre os valores de reflectância e uniformizar as imagens. Foram utilizadas as variáveis mostradas a seguir para parametrizar o submodelo espectral: i) reflectância das bandas individuais do sensor ETM+/Landsat (B3, B4, B5, B7); ii) os Índices de Vegetação por Diferença Normalizada (NDVI) e Ajustado para o Solo (SAVI); iii) as frações da reflectância obtidas pelo modelo linear de mistura espectral: vegetação (Veg), solo (Sl) e sombra (Sb); iv) as variáveis oriundas da transformação Tasseled Cap: Brightness (B), Greenness (G) e Wetness (W).

Em 2010, [27] utilizou o sistema Invernada para criar um modelo de crescimento levando em consideração dados meteorológicos. Também utilizou-se CROPGRO que é um modelo mecanístico que prediz a produção e composição de culturas utilizando informações de planta, clima, manejo e solo, e também há simulações de balanço hídrico e de nitrogênio, matéria orgânica e dinâmica de resíduos do solo e danos por praga/doenças.

Em 2011, [7] propôs a predição da taxa média de acúmulo de matéria seca utilizando dados agrometeorológicos, através de modelos empíricos de regressão linear simples e múltipla. Para realizar regressão linear simples foi utilizado o Proc Reg e para a regressão linear múltipla Proc Stepwise.

No mesmo ano, [5] realizou cálculos do rendimento potencial comparando três modelos matemáticos: de Loomis e Williams, que utiliza apenas a radiação solar incidente como parâmetro de entrada, implicando na predição do maior rendimento total de forragem; de Sinclair, que usa parâmetros relacionados com a estrutura da pastagem, como Índice de Área Foliar (IAF) e coeficiente de extinção luminosa; e de Doorenbos e Kassam, que considera aspectos fisiológicos

relativos à cultura, como IAF e perdas por respiração e também o ambiente, como por exemplo radiação incidente, temperatura, fotoperíodo e nebulosidade.

Em 2019, foi proposto um modelo inovador de predição de disponibilidade de forragem baseado em aprendizado de máquina, especificamente Redes Neurais Convolucionais (Convolutional Neural Networks - CNN) do tipo Long Short-Term Memory (LSTM) [22,23]. Esse modelo leva em conta dados históricos sobre corte de pastagem através de um método direto e também dados meteorológicos coletados pela estação automática presente na Embrapa Pecuária Sul, localizada em Bagé, normalizados e complementados por um agrometeorologista.

Todos os trabalhos encontrados na literatura focam apenas no modelo de predição, diferenciando-se do presente trabalho que propõe o desenvolvimento de um sistema que disponibilize a predição futura para áreas com pastagem nativa, a partir de mecanismos automáticos de coleta e processamento de dados remotos, sendo os seus componentes expostos na seção 3.

3 Materiais e Métodos

Nesta seção são apresentados o ambiente e ferramentas utilizadas, assim como as fontes de dados, processamento e visualização dos resultados. Essas etapas são partes do sistema baseado em FMIS proposto, chamado de TouceiraTech. A Figura 1 apresenta a arquitetura desse sistema, onde cada um dos retângulos simboliza um módulo do sistema. O primeiro módulo representa todas as entradas, podendo ser de diferentes fontes, que serão aceitas pelo sistema. O segundo módulo, de descrição de entradas, para que seja possível reconhecer diferentes fontes de dados de pastagem. Um módulo de Extract, Transform, Load (ETL) para que os dados das diferentes fontes sejam enviados adequadamente para o banco de dados. O módulo de armazenamento que utiliza um banco de dados geográfico. Um módulo de seleção de informação essenciais que serão passadas para o próximo módulo de Aprendizado de Máquina, na qual é responsável pela realização da predição e por fim um módulo de visualização dos resultados de predição.

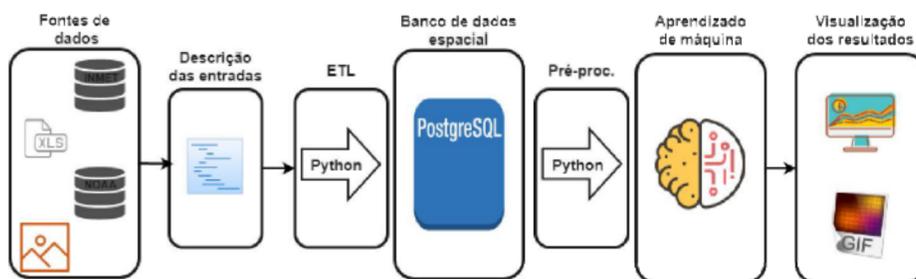


Figura 1. Arquitetura proposta para o sistema TouceiraTech.

3.1 Ambiente e ferramentas

Para o desenvolvimento do trabalho foi utilizado a linguagem Python. Foi criado um ambiente através da plataforma Anaconda, permitindo instalar todos os pacotes necessários para o desenvolvimento as etapas do trabalho. Para realizar o armazenamento dos dados foi utilizado SGBD PostgreSQL que é um BD objeto-relacional. Vale ressaltar que foi feita uma adaptação no modelo de BD proposto anteriormente [22,23]. Foi utilizada a extensão PostGIS, para o armazenamento de imagens de satélite e de aerolevantamentos ao banco, necessárias para a incorporação de métodos indiretos de amostragem.

3.2 Fontes de dados

A Embrapa Pecuária Sul realiza rotineiramente o manejo da pastagem baseado na disponibilidade de forragem, utilizando dados históricos de coleta de amostras através de um método direto de amostragem estratificada. Para realizar a coleta de amostras em pontos específicos das pastagens, são utilizadas gaiolas que isolam áreas do pastejo e tesouras, para corte do pasto. A área experimental contém divisões de pasto que correspondem a uma área infestada pelo capim-annoni há um longo período. Cada uma dessas divisões recebe um tipo de tratamento. O tratamento chamado Infestado, contém uma área mais homogênea, cuja vegetação é dominada pelo capim-annoni, salvo algumas pequenas frações que ainda apresentam vegetação nativa. O segundo tratamento, recebe práticas de manejo do Método Integrado para Recuperação de Pastagens (MIRAPASTO), com isso, é possível verificar uma maior diversidade de vegetação nativa.

Para a execução do sistema foram utilizados dados de pastagens disponibilizados pela Embrapa Pecuária Sul. Esses dados são armazenados originalmente em planilhas no formato XLS. Através de um *script* em Python as planilhas são lidas e as informações necessárias para o módulo de processamento são armazenadas no banco de dados.

Foram utilizados dados meteorológicos das bases de dados do Instituto Nacional de Meteorologia (INMET). A coleta dos dados do INMET foi feita em duas etapas: a primeira utilizando um *script* que gera informações sobre a estação automática de interesse, essas informações são gravadas em um arquivo no formato .json que é utilizado como entrada na próxima etapa. A segunda etapa utilizando um *script* de coleta em Python que, por meio do arquivo .json, obtém os dados da estação meteorológica e gera um arquivo .csv. Nesses mesmos *scripts*, os dados são automaticamente armazenados no banco de dados. A coleta dos dados de previsão meteorológica é feita através de um *script* chamado rdams-client, disponibilizado pela Research Data Archive (RDA). Os dados foram adquiridos a partir do *dataset* NCEP GFS 0.25 Degree Global Forecast Grids Historical Archive - ds084.1. As previsões feitas pelo National Center for Atmospheric Research (NCAR) utilizam o modelo americano Global Forecast System (GFS), executado quatro vezes por dia (00 UTC, 06 UTC, 12 UTC e 18 UTC).

Para que fosse possível realizar os testes do sistema proposto, primeiramente foi necessário realizar o cálculo de evapotranspiração. Esse cálculo foi realizado

através da de um pacote em Python chamado PyETo. Com este pacote foi possível fazer o cálculo utilizando três métodos: o de Penman-Monteith, Hargreaves e Thornthwaite. Para o trabalho foi utilizado o método de Penman-Monteith, devido ao fato dos valores de evapotranspiração já presentes no banco de dados serem calculados através desse método.

3.3 Processamento

A predição utiliza o modelo anteriormente proposto [22,23], composto por uma CNN com duas unidades LSTM. A primeira unidade LSTM possui trinta neurônios e a segunda possui 15 neurônios e, ambas, possuem a função de ativação tangente hiperbólica. Através do modelo, é possível realizar a predição da disponibilidade no passado, no presente e no futuro.

3.4 Visualização dos resultados

A visualização dos resultados do modelo de predição é atualmente realizada por meio de gráficos, conforme apresentado na Seção 4. Objetiva-se em um segundo momento aprimorar a visualização dos resultados para serem apresentados em formato GIF, representando a variação na disponibilidade de matéria seca no período desejado, tanto no passado como no futuro.

4 Resultados

Esta seção apresenta os resultados obtidos nos experimentos para verificação da acurácia do método de cálculo automatizado da evapotranspiração, de diferentes fontes de dados de previsão meteorológica e da predição da disponibilidade de matéria seca para cenários futuros.

4.1 Evapotranspiração

Para validar os resultados foram calculados utilizando o pacote PyETo os valores de evapotranspiração de referência (ETo) para os mesmos dias que já estavam presentes no banco de dados e que anteriormente haviam sido calculados por um Agrometeorologista na Embrapa Pecuária Sul, sendo bastante complexo de fazê-lo de forma manual. O cálculo realizado através desse método utiliza dados como: localização, temperatura, umidade, radiação, constante psicrométrica e fluxo de calor no solo. É importante ressaltar que se algum dos dados não estiver disponível, o pacote fornece funções para que seja possível estimar o valor da variável a partir da localização.

A Figura 2 apresenta os resultados obtidos pelo pacote PyETo (linha vermelha) *versus* os resultados obtidos manualmente (linha azul), o eixo x do gráfico mostra para quais dias foi realizado o cálculo e o eixo y mostra o valor de evapotranspiração. Vale ressaltar que o cálculo foi feito para um intervalo maior, no gráfico estão expressos apenas 15 dias para melhor visualização. É possível notar que os valores obtidos são similares e que as curvas apresentadas se assemelham em relação ao comportamento.

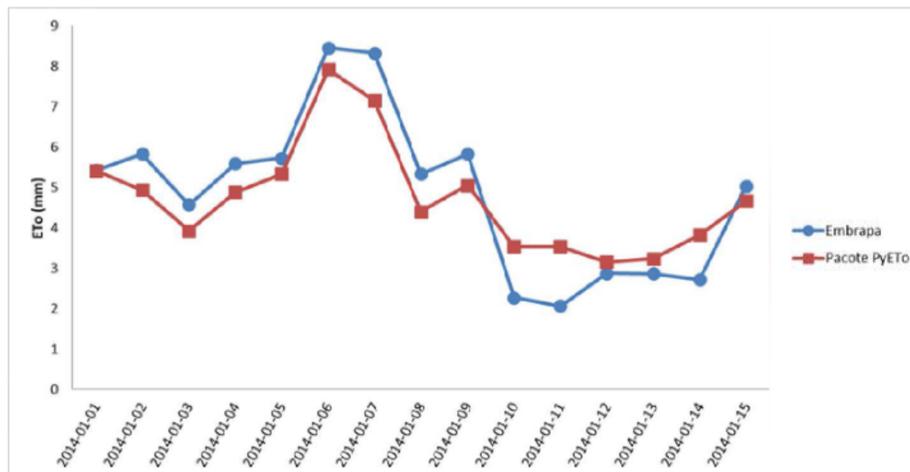


Figura 2. Diferença entre valores de evapotranspiração calculados pelo pacote PyETo e calculados na Embrapa Pecuária Sul, na qual o eixo x representa os dias que foram usados para teste e o eixo y os valores de evapotranspiração.

5 Previsão meteorológica

A Figura 3 mostra os valores coletados remotamente de três fontes de dados meteorológicos: dados históricos reais obtidos a com rede de estações automáticas do Instituto Nacional de Meteorologia (INMET), órgão do Ministério da Agricultura, Pecuária e Abastecimento (MAPA); dados de previsão providos Centro de Previsão de Tempo e Estudos Climáticos (CPTEC) do Instituto Nacional de Pesquisas Espaciais (INPE); e dados de previsão global disponibilizados pelo National Center for Atmospheric Research (NCAR), patrocinado pela National Science Foundation (NSF) e baseado no modelo de previsão americano. A partir destes conjuntos de dados foi possível comparar a acurácia da previsão dos diferentes modelos adotados pelo CPTEC e NCAR quando contrastados com os dados reais observados nas estações do INMET. O gráfico mostra no eixo x para quais dias foram realizadas as previsões e o eixo y apresenta a temperatura em graus Celsius. As curvas em tons de azul representam os valores de temperatura máxima e mínima para os valores obtidos através do CPTEC, as curvas em tons de verde representam os valores obtidos através do NCAR e as linhas vermelha e laranja representam os valores reais de temperatura máxima e mínima obtidos através da estação automática do INMET. A partir dos valores obtidos pode-se notar que as curvas correspondentes para temperatura máxima e mínima tem um comportamento bastante similar na maioria dos dias. As previsões tanto do NCAR quanto do CPTEC apresentaram um erro maior em relação a temperatura mínima do que comparado ao erro apresentado para a previsão de temperatura máxima.

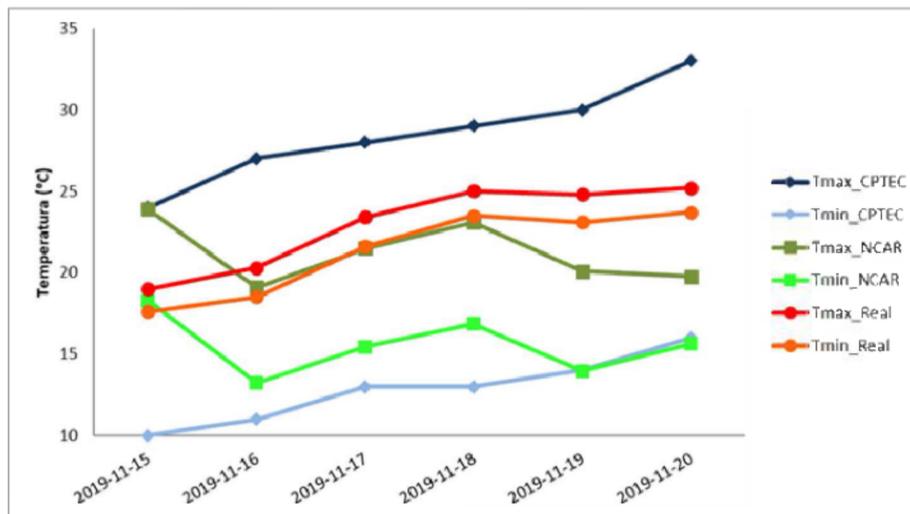


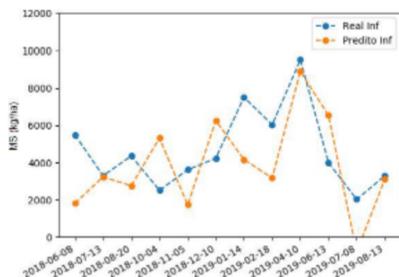
Figura 3. Valores de previsão meteorológica obtidos através do NCAR *versus* CPTEC, onde o eixo x mostra para quais dias foram coletadas as previsões e o eixo y apresenta a temperatura em graus Celsius.

6 Predição de Matéria Seca

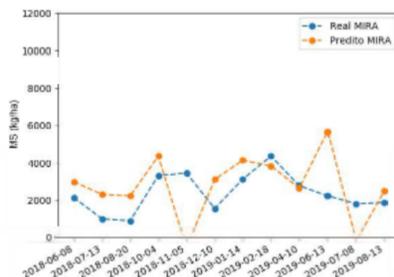
A Figura 4 apresenta os resultados do modelo de predição para o futuro no qual foram passadas como entrada para a CNN LSTM um total de 48 amostras válidas no tratamento Infestado (36 para treinamento e 12 para testes) e 44 no tratamento MIRAPASTO (32 para treinamento e 12 para testes). A variação do número de amostras por tratamento ocorre em função da exclusão de amostras que estavam com algum tipo de avaria, como, por exemplo, a gaiola estar virada. A divisão foi pensada dessa maneira para que fosse possível utilizar um intervalo de dados de 12 meses, com isso, podendo observar o crescimento em todas as estações do ano. Em todos os gráficos apresentados o eixo x representa para quais dias foram realizadas as predições e o eixo y representa a quantidade de MS em kg/ha.

As Figura 4(a) e 4(b) mostram os resultados de predição para o tratamento Infestado e MIRAPASTO, respectivamente, com valores de evapotranspiração calculados manualmente. Já as Figuras 4(c) e 4(d) apresentam os resultados do modelo de predição para os tratamentos Infestado e MIRAPASTO, respectivamente, utilizando valores de ETo calculados através do pacote PyETo.

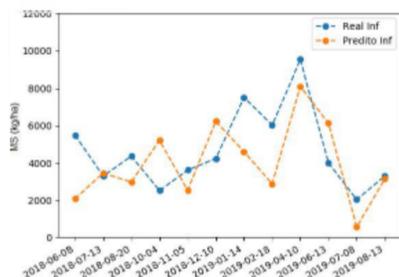
Foi realizada a predição utilizando valores de evapotranspiração calculados apenas pelo pacote PyETo com o intuito de validar o pacote. Comparando as Figuras 4(a) com 4(c) e 4(b) com 4(d) é possível notar que o comportamento das curvas se manteve o mesmo, o que indica que os resultados estão próximos, porém, é possível obter dados mais precisos melhorando os atributos passados para realização do cálculo.



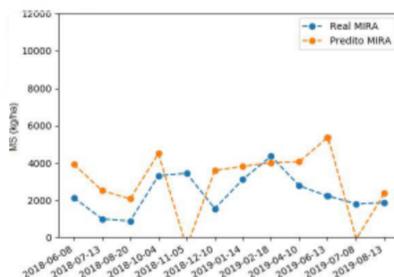
(a) Resultado de predição para o tratamento Infestado utilizando valores de ETo calculados manualmente.



(b) Resultado de predição para o tratamento MIRAPASTO utilizando valores de ETo calculados manualmente.



(c) Resultado de predição para o tratamento Infestado com valores de ETo calculados pelo pacote PyETo.



(d) Resultado de predição para o tratamento MIRAPASTO com valores de ETo calculados pelo pacote PyETo.

Figura 4. Predição futura para os tratamentos Infestado (Inf) e MIRAPASTO (MIRA) com dados de evapotranspiração (ETo) calculados manualmente na Embrapa Pecuária Sul e pelo pacote PyETo, na qual o eixo x representa as datas de predição e o eixo y os valores de MS em kg/ha.

7 Discussão

O protótipo do sistema de predição apresenta funcionalidades capazes de comprovar o seu potencial uso, realizando coletas automáticas, armazenando e processando dados para que seja possível prever a estimativa de massa de forragem. A partir dos resultados preliminares obtidos é possível verificar a acurácia do módulo de predição. Também foi possível validar a biblioteca PyETo que realiza o cálculo de evapotranspiração através do método de Penman-Monteith. Os valores de evapotranspiração estão bem próximos dos valores calculados na Embrapa Pecuária Sul, o que mostra a possibilidade de automatizar o cálculo, já que esse é bem complexo e utiliza um número significativo de variáveis. Porém, alguns refinamentos ainda são necessários para que os valores obtidos mostrem com exatidão a realidade. Outra análise pode ser feita em relação aos dados de previsão meteorológica e com isso mensurar o erro dos modelos, visto que foi comparado um modelo global e um modelo local.

8 Conclusão

De forma geral, os estudos mostraram a importância de um método de predição de disponibilidade de forragem. Com a implementação da coleta automatizada de dados meteorológicos, um dos objetivos essenciais do trabalho, é possível notar a sua significativa relevância para o desenvolvimento do sistema baseado em FMIS, visto que, a inserção manual de dados é bastante custosa em relação ao tempo demandado para tal tarefa.

Foi possível constatar que para que a predição de disponibilidade futura utilizando dados de previsão meteorológica se torne mais relevante, é necessário um conjunto de dados futuros de maior abrangência, superior aos quinze dias utilizado até então. Com isso serão buscadas novas fontes de dados de previsão que disponibilizem dados para um intervalo maior de tempo.

Considerando a adequada acurácia apresentada pelo modelo de predição, ainda assim se faz necessário um método indireto que seja capaz de gerar mais amostras de dados referentes à pastagem, assim, aumentará o número de entradas para a rede neural convolucional LSTM tanto para treinamento quanto para teste, com isso, espera-se que o modelo torne-se ainda mais preciso.

Também é possível constatar a partir dos resultados gerados que a predição no cenário onde a área está infestada, na maioria dos casos, apresenta uma subestimação da disponibilidade de forragem. Já para o cenário onde há o controle do capim-annoni, na maioria dos casos, há uma superestimação da disponibilidade de massa de forragem.

Com as funcionalidades do sistema desenvolvidas até então, há um grande potencial para que o sistema auxilie o pecuarista a mensurar a taxa de lotação de áreas de pastejo, proporcionando aos animais alimentação adequada sem a degradação da pastagem, e ao mesmo tempo reduzindo o gasto com a alimentação dos animais.

Agradecimentos

O presente trabalho foi realizado com suporte da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, tendo em vista o vínculo dos autores ao Programa de Pós-Graduação em Computação Aplicada (PPGCAP), resultado da cooperação entre UNIPAMPA e EMBRAPA, incluindo uma bolsa de mestrado. Parte do trabalho foi desenvolvido com o apoio do Programa de Auxílio da Pós-Graduação (PAPG) da UNIPAMPA.

Referências

1. Baruselli, P.S., Catussi, B.L.C., de Abreu, L.Â., Elliff, F.M., da Silva, L.G., Batista, E.S., Crepaldi, G.A.: Evolução e perspectivas da inseminação artificial em bovinos. *Revista Brasileira Reprodução Animal* **43**(2), 308–314 (2019)
2. Batista, G.E.d.A.P., et al.: Pré-processamento de dados em aprendizado de máquina supervisionado. Ph.D. thesis, Universidade de São Paulo (2003)
3. Camargo, Â.P.d., Camargo, M.B.P.d.: Uma revisão analítica da evapotranspiração potencial. *Bragantia* **59**(2), 125–137 (2000)
4. Camilo, C.O., Silva, J.C.d.: Mineração de dados: conceitos, tarefas, métodos e ferramentas. Universidade Federal de Goiás pp. 1–29 (2009)
5. Costa, N.d.L., Giostri, A.F., de Oliveira, R.A., Moraes, A.d.: Estimativa do rendimento potencial de azevém anual (*lolium multiflorum lam.*) através de modelos matemáticos. *Embrapa Roraima-Artigo em periódico indexado (ALICE)* (2011)
6. Council, B.C.R.: Grazing management (03 2019), <https://www.beefresearch.ca/research-topic.cfm/grazing-management-48>
7. Cruz, P.G.d., Santos, P.M., Pezzopane, J.R.M., Oliveira, P.P.A., Araujo, L.C.d.: Modelos empíricos para estimar o acúmulo de matéria seca de capim-marandu com variáveis agrometeorológicas. *Pesquisa Agropecuária Brasileira* **46**(7), 675–681 (2011)
8. Cunha, W.F.d.: Métodos indiretos para estimativa de massa de forragem em pastagens de *cynodon spp.* Ph.D. thesis, Universidade de São Paulo (2002)
9. Edvan, R.L., Bezerra, L.R., Marques, C.A.T., Carneiro, M.S.S., Oliveira, R.L., Ferreira, R.R.: Methods for estimating forage mass in pastures in a tropical climate. *Revista de Ciências Agrárias* **39**(1), 36–45 (2016)
10. Estrada, C.L.H., Nascimento, D.J., Regazzi, A.J.: Efeito do número e tamanho do quadrado nas estimativas pelo botanal da composição botânica e disponibilidade de matéria seca de pastagens cultivadas. *Revista da Sociedade Brasileira de Zootecnia* **20**(5), 483–493 (1991)
11. Fernandes, H.J., Paulino, M.F., Martins, R.G.R., Valadares Filho, S.d.C., Torres, R.d.A., Paiva, L.M., Moraes, G.F.B.K.d.: Ganho de peso, conversão alimentar, ingestão diária de nutrientes e digestibilidade de garrotes não-castrados de três grupos genéticos em recria e terminação. *Revista Brasileira de Zootecnia* **33**(6), 2403–2411 (2004)
12. Fonseca, E.L.d., Formaggio, A.R., Ponzoni, F.J.: Estimativa da disponibilidade de forragem do bioma campos sulinos a partir de dados radiométricos orbitais: parametrização do submodelo espectral. *Ciência Rural* **37**(6), 1668–1674 (2007)
13. Galvão, N.D., Marin, H.d.F.: Técnica de mineração de dados: uma revisão da literatura. *Acta Paulista de Enfermagem* **22**(5), 686–690 (2009)

14 Authors Suppressed Due to Excessive Length

14. Jhuria, M., Kumar, A., Borse, R.: Image processing for smart farming: detection of disease and fruit grading. In: IEEE Second International Conference on Image Information Processing (ICIIP-2013). pp. 521–526. IEEE (2013)
15. Lopes, M.A.: Informática aplicada à bovinocultura. FUNEP (1997)
16. Machado, J.G.d.C.F.: A adoção da identificação eletrônica de animais na gestão do empreendimento rural: um estudo multicaso na pecuária de corte. *Revista Hispici & Lema* **7**, 14 (2003)
17. Massruhá, S.M.F.S., Leite, M.A.d.A., Luchiari Junior, A., Romani, L.A.S.: Tecnologias da informação e comunicação e suas relações com a agricultura. *Embrapa Informática Agropecuária-Livro científico (ALICE)* (2014)
18. Melado, J.: Pastagem ecológica e serviços ambientais da pecuária sustentável. *Revista de Política Agrícola* **16**(3), 113–118 (2007)
19. Murakami, E., Saraiva, A.M., Junior, L.C.M.R., Cugnasca, C.E., Hirakawa, A.R., Correa, P.L.P.: An infrastructure for the development of distributed service-oriented information systems for precision agriculture. *Computers and Electronics in agriculture* **58**(1), 37–48 (2007)
20. Rajasekaran, T., Anandamurugan, S.: Challenges and applications of wireless sensor networks in smart farming - a survey. In: *Advances in big data and cloud computing*, pp. 353–361. Springer (2019)
21. Salman, A.K.D., Soares, J.P.G., Canesin, R.C.: Métodos de amostragem para avaliação quantitativa de pastagens. *Embrapa Rondônia. Circular Técnica* (2006)
22. Schulte, L.G.: Suporte à decisão em pastagens: análise espaço-temporal e aprendizado de máquina para predição da disponibilidade de forragem no contexto de smart farming. Master's thesis, Universidade Federal do Pampa (2019)
23. Schulte, L.G., Perez, N.B., de Pinho, L.B., Trentin, G.: Decision support system for precision livestock: Machine learning-based prediction module for stocking rate adjustment. In: *Proceedings of the XV Brazilian Symposium on Information Systems. SBSI'19, Association for Computing Machinery, New York, NY, USA* (2019). <https://doi.org/10.1145/3330204.3330222>, <https://doi.org/10.1145/3330204.3330222>
24. Sørensen, C.G., Fountas, S., Nash, E., Pesonen, L., Bochtis, D., Pedersen, S.M., Basso, B., Blackmore, S.B.: Conceptual model of a future farm management information system. *Computers and electronics in agriculture* **72**(1), 37–47 (2010)
25. Souto, M.C.P.d., Lorena, A.C., Delbem, A.C.B., Carvalho, A.C.P.L.F.d.: Técnicas de aprendizado de máquina para problemas de biologia molecular. *Sociedade Brasileira de Computação* (2003)
26. Tanaka, L.C., Camargo, F.M., Gotardo, R.A.: Sistema gerenciador de banco de dados: sgbd exist xml. *Revista Eletrônica de Sistemas de Informação e de Gestão Tecnológica* **2**(1), 70–86 (2012)
27. Tonato, F., Barioni, L.G., Pedreira, C.G.S., Dantas, O.D., Malaquias, J.V.: Desenvolvimento de modelos preditores de acúmulo de forragem em pastagens tropicais. *Pesquisa Agropecuária Brasileira* **45**(5), 522–529 (2010)
28. Trigo, I.A., Yada, M.M., da Silva Lourençano, L., de Lima, Y.K.: Uso da tecnologia na rastreabilidade do rebanho de corte. *Revista Interface Tecnológica* **15**(2), 381–391 (2018)
29. Wolfert, S., Ge, L., Verdouw, C., Bogaardt, M.J.: Big data in smart farming - a review. *Agricultural Systems* **153**, 69–80 (2017)