

UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO
CURSO DE ENGENHARIA DE COMPUTAÇÃO

EDUARDO RODRIGUES DE FARIA FILHO
GABRIEL AUGUSTO DE VITO D'ABBADIA GUIMARÃES

UTILIZAÇÃO DE REDES NEURAIS RECORRENTES PARA PREDIÇÃO
DE CONTROLE DE ESTOQUE

TRABALHO DE CONCLUSÃO DE CURSO

GOIÂNIA

2019

**TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR
VERSÕES ELETRÔNICAS DE TRABALHO DE CONCLUSÃO DE CURSO DE
GRADUAÇÃO NO REPOSITÓRIO INSTITUCIONAL DA UFG**

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio do Repositório Institucional (RI/UFG), regulamentado pela Resolução CEPEC nº 1204/2014, sem ressarcimento dos direitos autorais, de acordo com a Lei nº 9610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira, a partir desta data.

1. Identificação do Trabalho de Conclusão de Curso de Graduação (TCCG):

Nome completo do autor: Eduarda Rodrigues de Faria Filho
Gabriel Augusto De Lita D'Abadia Guimarães

Título do trabalho: Utilizações de redes neurais recorrentes para
medicação de controle de estoque

2. Informações de acesso ao documento:

Concorda com a liberação total do documento SIM NÃO¹

Havendo concordância com a disponibilização eletrônica, torna-se imprescindível o envio do(s) arquivo(s) em formato digital PDF do TCCG.

Eduarda Filho

Assinatura do(a) autor(a)²

Ciente e de acordo:

[Assinatura]
Assinatura do(a) orientador(a)²

Data: 17 / 07 / 19

¹ Neste caso o documento será embargado por até um ano a partir da data de defesa. A extensão deste prazo suscita justificativa junto à coordenação do curso. Os dados do documento não serão disponibilizados durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

² A assinatura deve ser escaneada.

EDUARDO RODRIGUES DE FARIA FILHO
GABRIEL AUGUSTO DE VITO D'ABBADIA GUIMARÃES

**UTILIZAÇÃO DE REDES NEURAS RECORRENTES PARA PREDIÇÃO
DE CONTROLE DE ESTOQUE**

Trabalho de Conclusão de Curso apresentada como requisito parcial à obtenção do título de Bacharel em Engenharia da Computação, da Escola de Engenharia Elétrica, Mecânica e Computação, da Universidade Federal de Goiás.

Orientador: Prof. Dr. Sandrerley Ramos Pires

GOIÂNIA

2019

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

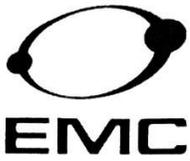
De Vito D'Abbadia Guimarães, Gabriel Augusto
Utilização de redes neurais recorrentes para predição de controle de estoque [manuscrito] / Gabriel Augusto De Vito D'Abbadia Guimarães, Eduardo Rodrigues de Faria Filho. - 2019.
54 f.

Orientador: Prof. Dr. Sandrerley Ramos Pires.
Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Goiás, Escola de Engenharia Elétrica, Mecânica e de Computação (EMC), Engenharia de Computação, Goiânia, 2019.
Bibliografia. Apêndice.

Inclui abreviaturas, símbolos, gráfico, tabelas, algoritmos, lista de figuras, lista de tabelas.

1. Redes Neurais. 2. Redes Recorrentes. 3. Estoque. 4. Controle. 5. LSTM. I. de Faria Filho, Eduardo Rodrigues. II. Ramos Pires, Sandrerley, orient. III. Título.

CDU 62:004.3/4



ATA DE AVALIAÇÃO DE PROJETO FINAL

CURSO

() Eng. Elétrica () Eng. Mecânica (X) Eng. de Computação
() Projeto Final 1 (X) Projeto Final II

AVALIAÇÃO DE PROJETO FINAL

Título do projeto: Utilização de Redes Neurais Recorrentes para
Previsão de Controle de Estoque

BANCA AVALIADORA

Membro 1: SANDRELEY RAMOS FIZES
Membro 2: CARLOS GALVÃO PINHEIRO SÊNIOR
Membro 3: THYAGO CARVALHO MANGUET

ESTUDANTES

Matricula	Nome
201204345	Eduardo Rodrigues de Faria Filho
201206878	Gabriel Augusto de Vito D'Abadia Guimarães

NOTAS

Matricula	Membro 1				Membro 2				Membro 3				Média
	NPT	NTE	NAA	NF	NPT	NTE	NAA	NF	NPT	NTE	NAA	NF	
201204345				8,5				8,5				8,5	
201206878				8,5				8,5				8,5	

NPT – Nota plano de trabalho; NTE – Nota do trabalho escrito; NAA – Nota de apresentação e arguição
Para Eng. Elétrica, Mecânica e PFC2 da Eng. Da Computação: $NF = 0,1 \times NPT + 0,45 \times NTE + 0,45 \times NAA$
Para PFC1 da Eng. Da Computação: $NF = 0,3 \times NPT + 0,7 \times NAA$

Goiânia, 5 de Julho de 20 19.

Sandreley Ramos Fizes
Membro 1
Carlos Galvão Pinheiro Sênior
Membro 2
Thyago Carvalho Manguet
Membro 3

AGRADECIMENTOS

Eduardo Rodrigues de Faria Filho

Ao professor e orientador desta monografia, Prof. Dr. Sandrerley Pires, por toda sua dedicação e paciência no complexo trabalho de nos instruir à conclusão deste trabalho, e ainda por toda sua capacidade de nos motivar mesmo em meio a tantas dificuldades diárias. Aos meus familiares e amigos, os quais sempre estão dispostos a me apoiar e ajudar a renovar minhas forças diárias.

Gabriel Augusto De Vito D'Abbadia Guimarães

Agradeço, antes de tudo, à minha mãe, Daniela, a pessoa mais especial que eu tenho em minha vida hoje, pessoa em quem sempre me espelho, sempre forte e sorridente. À minha família, que sempre esteve presente em minha vida, sempre me apoiaram, me deram bons exemplos e são a base de toda a minha vida. À minha namorada, Amanda, que está lado a lado comigo em todos os momentos nos últimos anos, pessoa que eu admiro e amo muito. À minha avó Cornélia, responsável por me fazer tomar gosto pela computação desde cedo e por me ensinar cada vez mais sobre a vida como um todo. A todos os meus amigos, de infância, adolescência, capoeira e trabalho, que me ajudaram a crescer como pessoa e sempre estiveram por perto pra me apoiar nas melhores e piores horas da minha vida. A todos os meus professores, pessoas de respeito e que me deram uma formação de qualidade, mostrando que a vida acadêmica não é simples, mas é fruto de um esforço contínuo, disciplina, persistência e traquejo, mas é valiosa e grandiosa.

“I do not know what I may appear to the world, but to myself I seem to have been only like a boy playing on the sea-shore, and diverting myself in now and then finding a smoother pebble or a prettier shell than ordinary, whilst the great ocean of truth lay all undiscovered before me.”

(Isaac Newton)

RESUMO

O presente trabalho visa estudar as Redes Neurais Recorrentes (RNN) como método para predição da quantidade de estoque necessária de milho debulhado para determinado período. Sendo esse milho o produto mais comercializado de uma determinada empresa vendedora de produtos agrícolas. Diante disso, foi feito um estudo das séries históricas de vendas do produto em questão e assim confrontado períodos passados para a predição em períodos futuros.

Palavras-chave: Redes Neurais Recorrentes. Predição de Estoque. Inteligência Artificial.

ABSTRACT

The present work aims at studying the Recurrent Neural network (RNN) as a method for prediction of the amount of stock needed for the given period of maize deseeded. Being that the corn product marketed for a specific seller of agricultural products. Before that, it was made a study of the historical series of sales of the product in question and so confronted past periods for the prediction in future periods.

Keywords: Recurrent Neural Network, Inventory Prediction, Artificial Intelligence.

LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

ABMET	Associação Brasileira de Meteorologia
CNC	Confederação Nacional do Comércio
CSV	Comma-Separated-Value
RNA	Rede Neural Artificial
RNN	Recurrent Neural Network
RNR	Rede Neural Recorrente
UFG	Universidade Federal de Goiás

LISTA DE ILUSTRAÇÕES

Figura 1 Neurônio biológico	18
Figura 2 Esquema de um neurônio artificial proposto por McCullock e Pitts (denominado Neurônio-MCP)	18
Figura 3 Perceptron	20
Figura 4 Exemplo de uma rede multicamadas	21
Figura 5 Exemplo de uma rede neural recorrente com realimentação das saídas para a camada oculta.....	23
Figura 6 Rede neural recorrente em 4 períodos distintos.....	24
Figura 7 Estrutura de uma rede neural recorrente de Elman.....	25
Figura 8 Diferentes tipos de aplicações usando redes neurais recorrentes	26
Figura 10 Demanda diária de milho nos seis primeiros meses de 2018	28
Figura 11 Demanda mensal de milho debulhado, entre agosto de 2008 a março de 2019	28
Figura 12 Demanda diária de sorgo nos 6 primeiros meses de 2018.....	29
Figura 13 Demanda mensal de sorgo de agosto de 2008 a março de 2019.....	30
Figura 14 Chuva acumulada mensal de janeiro de 2009 a março de 2019 em Pirenópolis-GO	30
.....	
Figura 15 Tableau após o pré-processamento dos dados de milho debulhado.....	32
Figura 16 Comportamento da função de ativação ELU e sua derivada	33
Figura 17 Resultado experimental do treinamento da rede neural recorrente utilizando dados de vendas do sorgo	36
Figura 18 Gráfico de Previsão vs Demanda entre os períodos 14 e 34.....	37
Figura 19 Gráfico de Previsão vs Demanda entre os períodos 80 e 100.....	37
Figura 20 Resultado experimental do treinamento da rede neural recorrente utilizando dados de vendas do sorgo	39

SUMÁRIO

1	INTRODUÇÃO.....	11
1.1	O PROBLEMA.....	12
1.2	OBJETO DE ESTUDO	13
1.3	JUSTIFICATIVA	14
1.4	OBJETIVOS	14
1.4.1	Objetivo Geral	14
1.4.2	Objetivos Específicos	14
1.5	METODOLOGIA	15
2	REFERENCIAL TEÓRICO.....	17
2.1	REDES NEURAIS ARTIFICIAIS	17
2.1.1	Neurônio Biológico e Relação com um Neurônio Artificial	17
2.1.2	Processo de Aprendizado	19
2.1.3	Diferentes Arquiteturas de Redes Neurais Artificiais	20
2.2	REDES NEURAIS RECORRENTES (RNN).....	21
2.2.1	Definição.....	22
2.2.2	Casos de Uso.....	23
2.2.3	Arquitetura.....	23
2.2.4	Diversas Aplicações De Redes Neurais Recorrentes.....	25
3	METODOLOGIA.....	27
3.1	PROBLEMA.....	27
3.2	BASE DE DADOS	27
3.3	CARACTERIZAÇÃO E ANÁLISE DOS DADOS.....	27
3.4	O ALGORITMO.....	31
3.4.1	Pré-processamento e Transformação dos Dados	31
3.4.2	Separação dos Dados Para Treino e Teste	32
3.4.3	Processo de Treinamento Utilizando Redes Neurais Recorrentes.....	32
3.4.4	Observações Adicionais Sobre o Procedimento	33
4	RESULTADO	35
4.1	EXECUÇÃO DO ALGORITMO PARA OS DADOS DE VENDA DO MILHO DEBULHADO.....	35
4.2	EXECUÇÃO DO ALGORITMO PARA OS DADOS DE VENDA DO SORGO.....	38
4.3	COMPARATIVO ENTRE O MÉTODO INGÊNUO E REDES NEURAIS RECORRENTES	39
	APÊNDICE A – DADOS DE VENDAS MENSAS DE MILHO DEBULHADO ENTRE AGOSTO DE 2008 E MARÇO DE 2019	44
	APÊNDICE B – DADOS DE VENDAS MENSAS DE SORGO ENTRE O PERÍODO DE...	47
	APÊNDICE C – ALGORITMO UTILIZADO PARA O MILHO DEBLHADO	50

1 INTRODUÇÃO

Este trabalho atua na construção de uma solução automatizada para uma empresa de médio porte situada no interior de Goiás, mais precisamente no município de Campinorte, a qual é referência na região na comercialização de produtos agropecuários. Hoje essa empresa passa por uma necessidade de melhorar a gestão de seus estoques. Dentre os diversos produtos que ela comercializa, um recebe maior destaque, o milho debulhado, devido ao seu alto volume de vendas e dos problemas ocasionados por esse grande volume.

Esse produto de maior notoriedade é utilizado para diversos fins no meio agropecuário, particularmente na alimentação de frangos e porcos. Devido a essa alta demanda, a empresa percebeu a necessidade de um cuidado maior para gerenciar o armazenamento e a distribuição desse milho, evitando assim as perdas, tanto de mercadorias quanto da realização de transações de venda, isto é, as perdas financeiras.

Nos moldes atuais, o milho debulhado é armazenado em sacos capazes de armazenar até 60 kg e a empresa tem um grande galpão ao lado de sua loja, destinado, quase totalmente, ao armazenamento e à distribuição deste produto.

Atualmente, a empresa também possui um sistema de gestão empresarial, o qual possui todos os registros de vendas de seus produtos, inclusive o milho debulhado, desde o início do ano de 2009. Nesse sistema é armazenado a quantidade de produtos vendidos, a data da venda, o valor, a quantidade disponível em estoque e diversas outras informações relevantes para a gestão dessa empresa.

Uma das maiores dificuldades relatadas pelos gestores da empresa está em conseguir ter uma previsão da demanda futura da quantidade de milho debulhado que será vendida em um determinado período de tempo, mesmo que esse horizonte temporal fosse relativamente próximo. Eles relatam ainda que, caso essa previsão fosse possível, a empresa obteria diversas vantagens competitivas e uma grande redução de custos, sejam estes de armazenamento ou de compras feitas às pressas, trazendo vários benefícios para a empresa.

Foi relatado ainda que algumas vezes a empresa chegou a ficar sem estoque de milho debulhado, ocasionando diversos prejuízos como a perda de clientes e total insatisfação dos gestores. Também foi exposto que, caso eles tivessem a possível previsão da demanda, conseguiriam negociar melhor com seus fornecedores e obter maiores vantagens, não só quanto ao espaço de armazenagem, mas também no preço de compra dos produtos.

Após esses anos de experiência no mercado de produtos agropecuários, os gestores viram a necessidade de um estudo mais aprofundado de toda a gestão dos estoques de sua empresa,

principalmente quanto ao seu produto mais comercializado. Com a realização desse estudo, eles acreditam que certamente terão uma maior vantagem competitiva quando comparado a seus concorrentes, ajudando assim a trilhar um caminho de maior crescimento para a empresa.

Alguns possíveis métodos já foram cogitados pela empresa para a realização da possível predição da demanda, mas devido aos custos elevados relatados por esses gestores não foi possível colocar nenhum deles em prática. Dentre as principais dificuldades vistas quanto a esses métodos foram a falta de mão de obra qualificada, principalmente na região em que se situa a empresa, o alto custo dos serviços prestados para a realização desses serviços e ainda que alguns desses métodos devem ficar em constante revisão para continuar trazendo a informação de forma precisa.

Portanto, os gestores atualmente buscam um processo que seja o mais eficaz possível, com um valor não muito elevado de acordo com a realidade da empresa, e que com o passar do tempo esse método não precise passar por novas avaliações e estudos sucessivos para continuar revelando a análise da demanda de forma precisa. Dessa maneira, a ideia geral dos gestores é que o próprio sistema de gestão ou um sistema auxiliar, através de um processo inteligente conseguisse analisar o histórico de vendas armazenadas no banco de dados da empresa e, com esses dados, revelar a possível demanda necessária para um determinado período de tempo futuro.

Diante do panorama exposto, este trabalho propõe-se o desenvolvimento de um sistema de previsão de demandas, utilizando métodos estatísticos (quantitativos) e inteligência artificial, especificamente as Redes Neurais Recorrentes (RNNs). Este sistema deve ser capaz de prever a demanda de estoque da empresa de Campinorte. Ao final deste estudo, devemos produzir um algoritmo cujas entradas sejam a base de dados dos registros de suas vendas, disponibilizada pela empresa de gestão comercial e o intervalo de tempo em que se deseja calcular a previsão de demanda e a saída do algoritmo deve ser o valor da demanda em um período futuro.

A ideia é que este algoritmo desenvolvido seja, futuramente, incorporado ao sistema de gestão comercial, para que este consiga oferecer o serviço de previsão de demandas não somente à empresa de Campinorte, mas a todos os seus clientes.

1.1 O PROBLEMA

Dados confiáveis são fundamentais para que um gestor de uma empresa tome decisões da melhor maneira possível e ainda consiga fazer com que a empresa se mantenha competitiva em um mercado globalizado e concorrido.

A previsão de dados como vendas, demanda, estoque, dentre outros, é peça chave para uma boa gestão. “É preciso haver um norte para que a administração da produção possa trabalhar. A previsão de vendas oferece este direcionamento” (Peinaldo, 2007).

Uma análise da demanda de estoque consegue evitar o seu excesso ou a sua escassez, prepara melhor a equipe de vendas para alcançar as metas estipuladas, auxilia na elaboração de ações de marketing e atrai investidores.

No Brasil, de acordo com uma pesquisa realizada com mais de 6 mil lojas do País pela Confederação Nacional do Comércio (CNC), cerca de 30,7% dessas lojas tinham, no início de junho de 2018, estoques de bens duráveis acima do apropriado ao andamento do consumo e ainda cerca de 14,3% detinham estoque abaixo da quantidade considerada ideal.

O excesso de estoque resulta em capital que está imobilizada no negócio. Também significa custos adicionais com estrutura e manutenção, sem contar que produtos perecíveis podem vencer. Portanto, eliminar ou evitar este excesso é fundamental e elimina desperdício de recursos de tempo e dinheiro na empresa.

A falta de estoque faz com que a empresa fique com uma reputação ruim perante seus clientes, uma vez que houve uma demanda não respondida por parte da empresa, o que pode também ser visto pelo cliente como um descaso.

Segundo (Ritzman, Krajewski, & Klassen, 2004) o planejamento eficaz da demanda do cliente é um dos principais responsáveis pelo sucesso da cadeia de suprimentos, que se inicia com previsões precisas.

Dados do (SEBRAE, 2014) apontam que 50% das empresas que fecharam no período da pesquisa não definiram estratégias para evitar desperdícios. Este dado é alarmante e esses desperdícios estão, muitas vezes, ligados ao mau planejamento de estoques.

Sendo assim, o problema enfrentado com o controle de estoque pela empresa de Campinorte em relação ao milho debulhado também é enfrentado, de forma análoga, por diversas empresas em âmbito nacional e, até mesmo, global. Dessa forma, é possível ainda uma futura extensão dos estudos aqui apresentados em diversas outras realidades que se assemelham.

1.2 OBJETO DE ESTUDO

O objeto de estudo desse trabalho será a série temporal que compreende os dados de venda do milho debulhado ao longo de vários anos, os quais foram armazenados no banco de dados utilizado pelo sistema de gestão empresarial presente na empresa.

Além disso, durante o processo de refinamento do problema e construção da solução, outros fatores serão analisados a fim de determinar um conjunto suficiente de dados de entrada para que se obtenha uma previsão mais adequada possível. Entre esses fatores considera-se questões climáticas, situação econômica e outros que ainda serão analisados.

1.3 JUSTIFICATIVA

Avaliando este tema quanto a produção científica, o estudo de um método algorítmico para a previsão de demandas possui extrema relevância. A existência de uma maior quantidade de estudos nessa área abre a oportunidade para avanços significativos, que podem ainda beneficiar toda a sociedade.

A partir desses estudos acadêmicos, torna-se possível, em caso de resultados satisfatórios, a utilização do mesmo em ambientes corporativos, podendo ajudar inclusive empresas de pequeno e médio porte, as quais são as mais vulneráveis na competição diária do mercado.

O trabalho se justifica por permitir a difusão de novas formas de controle nos processos de empresas do ramo do agronegócio. Esses ramos em especial são fortemente impactados por um conjunto limitado de fatores, os quais podem ter o seu comportamento ao longo do tempo relativamente bem aproximados por séries temporais, sugerindo dessa forma o uso de redes neurais recorrentes.

1.4 OBJETIVOS

1.4.1 Objetivo Geral

Utilizando uma ferramenta de predição, baseada em inteligência artificial, prever a demanda de venda de milho debulhado que é comercializado pela empresa atendida neste trabalho.

1.4.2 Objetivos Específicos

- Realizar uma Revisão Bibliográfica Sistemática sobre algoritmos de inteligência artificial.
- Identificar os possíveis elementos internos e externos à empresa, que possam influenciar diretamente na predição da demanda de estoque de milho debulhado.
- Captar os dados históricos de vendas da empresa e dos fatores externos que influenciam na predição.

- Elaborar um algoritmo que seja capaz de relacionar os dados históricos (tanto de fatores externos quanto de vendas) da empresa, capaz de prever a quantidade ideal que ela deve ter em estoque em um determinado período.
- Confrontar resultados obtidos com uma demanda já conhecida de um período anterior para constatar a eficiência do algoritmo desenvolvido.

1.5 METODOLOGIA

Este trabalho toma como opção de técnica para a solução de previsão as redes neurais recorrentes. Essa escolha foi feita por se tratar da previsão de uma base de dados temporal (série temporal) e a grande maioria das séries temporais não possuem um caráter determinístico, e sim estocástico, devemos recorrer ao uso de técnicas baseadas no reconhecimento de padrões (como regressão e Redes Neurais Recorrentes) para a previsão de valores futuros de séries temporais de caráter estocástico.

Utilizaremos Redes Neurais Recorrentes (RNNs) devido ao seu modelo básico de funcionamento. “Como as RNNs incluem loops, elas podem armazenar informações ao processar uma entrada. Essa memória os torna ideais para tarefas de processamento onde as entradas anteriores devem ser consideradas (como dados da série temporal).” (IBM, 2017).

Este loop supracitado, nas camadas ocultas da rede neural, nos proporciona uma característica muito importante para a nossa aplicação: memória, produzida a partir de dados das camadas de iterações anteriores. Essa memória (que pode ser de curto ou longo prazo) será artifício essencial para conseguirmos prever dados de uma série temporal. Isso porque um único ponto de dados isoladamente em uma rede neural comum não é suficiente para que saibamos o comportamento da série temporal completa (por exemplo, a série está mudando? Crescendo? Encolhendo?). Desta forma, precisamos de um tipo de rede neural que consiga trazer, em cada neurônio, dados de neurônios anteriores, e as Redes Neurais Recorrentes são ideais para este tipo de aplicação.

Assim, para atingir os objetivos apresentados na seção 1.4, foi definida a seguinte estratégia:

1. Compreender a dinâmica de funcionamento do mercado de milho debrulhado no Brasil, investigando os fatores que afetaram as quantidades e preços neste mercado nos últimos 5 anos. Para realizar este estudo, buscaremos artigos e estudos já realizados na área, com resultados comprovados.
2. Buscar, junto à empresa que oferece o serviço de gestão comercial para a empresa objeto deste estudo, os dados históricos de vendas de milho debrulhado dos últimos anos. É

importante ressaltar que um dos integrantes deste trabalho é sócio da empresa que oferece este serviço, portanto, há um consentimento por parte de ambas as empresas conseguirmos estes dados.

3. Realizar pesquisa bibliográfica a respeito do estudo das redes neurais recorrentes, selecionando artigos e tutoriais para esse fim. Em seguida realizar a leitura dos artigos e estudo dos tutoriais a fim de habilitar a equipe na implementação da solução.

Desenvolver um algoritmo, utilizando Redes Neurais Recorrentes (RNR), capaz de aproximar uma série temporal, para conseguirmos prever a demanda de estoque em um determinado período utilizando os dados de venda de demandas passadas e dados externos.

4. Realizar o comparativo gráfico entre a previsão realizada pelo algoritmo e os dados reais de demanda, calculando o seu percentual de acerto. Para esta previsão, treinaremos o algoritmo com os dados de venda de milho debulhado da empresa em estudo, referentes a 4 anos atrás e faremos o teste do algoritmo com dados do último ano. Para verificarmos se os resultados obtidos com o algoritmo foram aceitáveis, os confrontaremos com os dados de vendas reais ocorridas no último ano, inserindo ambos em um único gráfico de linha e calculando o percentual de acerto.
5. Escrever a monografia relatando todas as atividades e os resultados obtidos na execução das atividades citadas anteriormente. Com a monografia em mãos preparar a apresentação para a defesa do projeto final de curso.

2 REFERENCIAL TEÓRICO

2.1 REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais consiste em modelos matemáticos e computacionais, inspirados na estrutura neural de organismos inteligentes, capazes de simular o aprendizado (seja ele supervisionado ou não).

Os primeiros estudos a respeito do assunto surgiram em 1943, quando Warren McCulloch e Walter Pitts fizeram uma analogia entre eletrônica e células nervosas, em um trabalho sobre “neurônios formais”. Neste trabalho foi simulado o comportamento das conexões sinápticas de um neurônio utilizando apenas resistores e amplificadores.

2.1.1 Neurônio Biológico e Relação com um Neurônio Artificial

Um neurônio é a unidade básica da estrutura cerebral e do sistema nervoso. Ele é responsável por conduzir impulsos nervosos através de sinapses de seus dendritos. O neurônio é constituído de corpo celular (diretamente ligado aos dendritos) e axônio.

A informação (mensagem) é transmitida dos dendritos ao corpo celular através da sinapse. O corpo celular, então, processa esta informação (que é transmitida através de impulsos elétricos) e propaga esta informação para o próximo neurônio através do axônio.

É através das sinapses que os neurônios conseguem se unir, formando uma rede neural.

Cada neurônio dentro da rede tem, entre várias funções, a função de permitir ou não o fluxo de determinada informação entre eles.

Um fato importante sobre o processo de transmissão de informação através dos neurônios é a presença de um limiar de disparo (também denominado threshold) presente nos axônios, que limita ou não a passagem da informação desde a sua origem nos sensores (papilas gustativas, olfato, audição ou outros sensores) até o próximo neurônio. Esta barreira consegue dizer se uma determinada informação é importante ou não.

Fonte 1 <http://deeplearningbook.com.br/o-neuronio-biologico-e-matematico/>

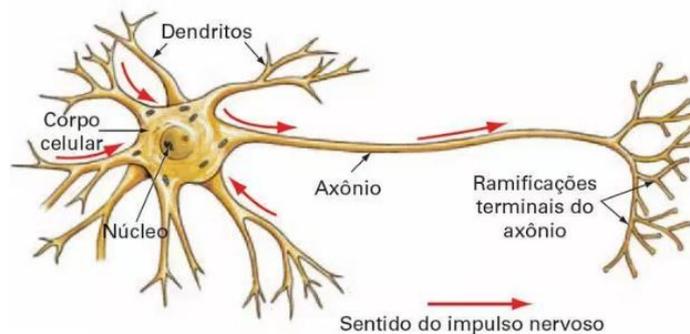


Figura 1 Neurônio biológico

Inspirados na biologia, em 1943 Warren McCulloch (psiquiatra e neuroanatomista) e Walter Pitts (matemático) projetaram o primeiro modelo de neurônio artificial, publicado no artigo *A Logic Calculus of the Ideas Immanent in Nervous Activity*.

O modelo proposto por eles está ilustrado na Figura 2.

Fonte 2 <http://conteudo.icmc.usp.br/pessoas/andre/research/neural/>

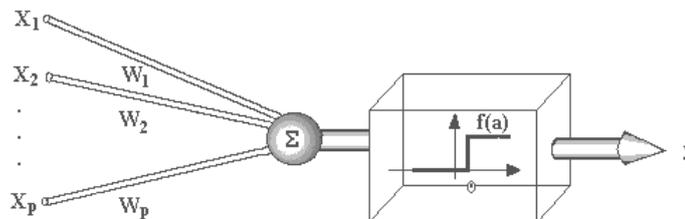


Figura 2 Esquema de um neurônio artificial proposto por McCulloch e Pitts (denominado Neurônio-MCP)

De maneira análoga ao neurônio biológico, as *entradas* (X_1, X_2, \dots, X_p) representam os impulsos elétricos vindos dos dendritos.

Cada sinal de entrada é multiplicado por um *peso sináptico* (representado pela letra W , na figura), que indica a importância desta entrada para o processamento da saída.

O somatório de todas as entradas ponderadas é, então, submetida a uma *função de transferência*, que determina se o neurônio será ativado ou não. A função de ativação representa o limiar de disparo (threshold) de um neurônio biológico.

Por fim, temos a *saída* do neurônio, representada pela letra Y na figura, que muitas vezes é comparada com uma saída esperada para recalcular os pesos até que a rede esteja *devidamente treinada* para um determinado modelo esperado.

2.1.2 Processo de Aprendizado

Em 1958, Frank Rosenblatt propôs uma topologia de rede denominada Perceptron, que constituía neurônios MCP (McCulloch Pitts) em duas camadas. A primeira camada possuía seus pesos sinápticos sempre fixos. Assim, o processo de aprendizado era transferido apenas para a segunda camada. Este estudo possibilitou, a partir de 1982, o treinamento de redes alimentadas adiante (redes feedforward) com múltiplas camadas.

Podemos destacar alguns elementos básicos do Perceptron:

- **Valores de entrada**, representados por x_1, x_2, x_n e são valores que serão inseridos na rede para encontrar algum padrão.
- **Pesos sinápticos**, representados por w_1, w_2, w_n , que são os valores que atribuirão a cada entrada um grau de importância na saída.
- **Viés**, também denominado *bias*, representado por $-\theta$, que é um elemento capaz de aumentar o grau de liberdade dos ajustes dos pesos sinápticos.
- **Potencial de ativação**, representado por u , que consiste no somatório das entradas, ponderadas por seus respectivos pesos sinápticos com o bias.
- Em termos matemáticos, o potencial de ativação pode ser definido como $\sum_t^n x_t w_t + b$.
- **Função de ativação**, representada pela letra g , é responsável por definir a ativação de saída do neurônio.
- **Valor de saída** (y) representa a saída real do sistema.

Fonte 3 <https://www.slideshare.net/EdmilsonNeto2/redes-neurais-62554685>

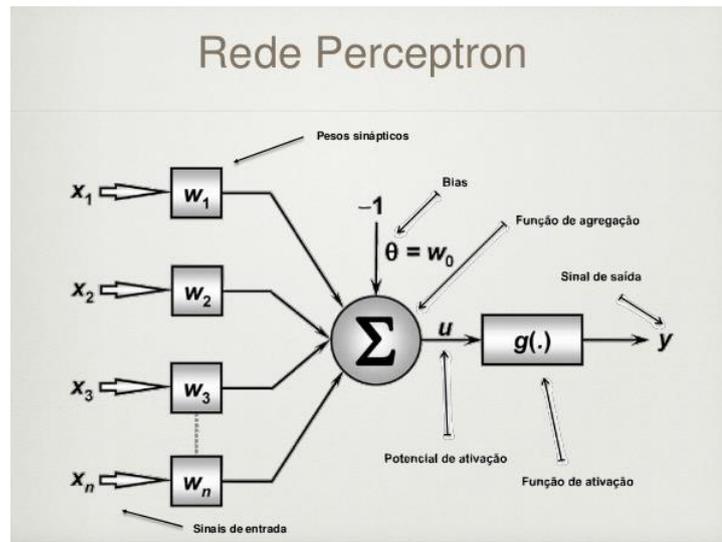


Figura 3 Perceptron

O processo de aprendizado de um Perceptron de uma camada consiste, basicamente, no seguinte algoritmo:

1. Inicializar os pesos sinápticos com valores randômicos ou iguais a zero.
2. Calcular o valor do potencial de ativação somando-se os valores de entrada com seus respectivos pesos sinápticos ($u = \sum x_t w_t + b$) e soma-se o bias.
3. Aplicar a função de ativação no potencial de ativação para gerar uma saída.
4. Calcular o erro na saída ($E_j = t_j - s_j$).
5. Caso o erro associado à saída seja diferente de 0, recalculer os pesos através da taxa de aprendizado ($\Delta w = \mu x_j E_j$).

2.1.3 Diferentes Arquiteturas de Redes Neurais Artificiais

A arquitetura de uma rede neural deve variar de acordo com a sua necessidade. Trata-se, basicamente, da maneira com que os neurônios estão organizados dentro da rede. Existem diversas maneiras com que os neurônios em uma rede neural podem ser dispostos. Dentre elas, podemos destacar:

- **Redes de única camada (single layer):** São redes cujos neurônios são dispostos em uma única camada. Suas entradas são enviadas diretamente à saída.
- **Redes Multicamadas:** É o tipo mais comum de redes neurais. São redes neurais que possuem camada de entrada, camada de saída e uma ou mais camadas ocultas (ou

intermediárias). Cada camada é composta por um ou mais neurônios que são conectados aos neurônios da camada seguinte. Os neurônios de uma camada propagam seus sinais até que cheguem à saída da rede.

Fonte 4 <https://medium.com/ensina-ai/rede-neural-perceptron-multicamadas-f9de8471f1a9>

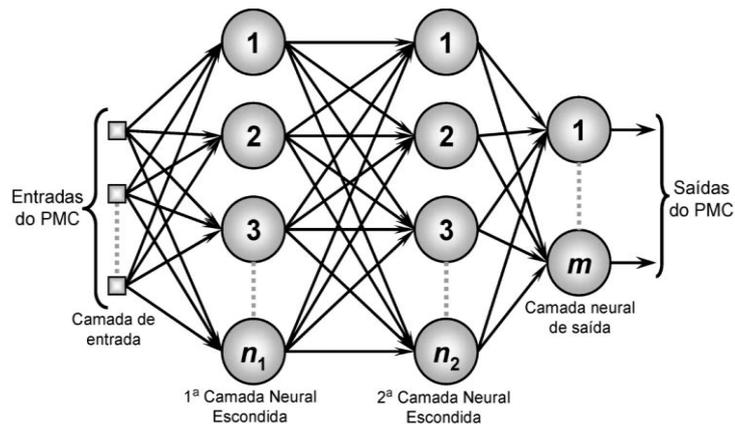


Figura 4 Exemplo de uma rede multicamadas

- **Redes FeedForward:** São redes em que a transmissão dos sinais de um neurônio para outro se dá sempre em apenas um sentido (da camada de entrada para a camada de saída da rede). Redes feedforward também são conhecidas como redes sem realimentação. Seus neurônios são agrupados em camadas e neurônios de uma mesma camada não são interligados entre si.
- **Redes Recorrentes:** São redes que possuem um ou mais conexões de realimentação em sua estrutura. Essas conexões podem ser entre camadas ou em torno do mesmo neurônio. Dentre as redes neurais recorrentes existentes, podemos destacar as redes de Elman e Jordan.

2.2 REDES NEURAIIS RECORRENTES (RNN)

Existem diversas situações na natureza em que um determinado evento é consequência direta de eventos anteriores. Estes eventos são denominados eventos sequenciais. Neste tipo de situação, um determinado dado ou valor não pode ser avaliado isoladamente. Ele é fruto e parte de uma sequência de outros valores.

Existem diversos exemplos de eventos sequenciais que podem ser observados cotidianamente: frames em um vídeo, a recitação do alfabeto, palavras dentro de uma frase coerente, o preço de uma ação na bolsa de valores, a temperatura de uma região em um determinado horário, a taxa de juros ou as vendas realizadas em um comércio.

O ser humano é capaz de projetar e se antecipar diante de situações sequenciais desde que ele tenha a capacidade de detectar o padrão sequencial de algum evento sequencial. Por exemplo, um goleiro sempre tenta se antecipar e se posicionar diante de uma bola que foi arremessada a uma velocidade constante, uma vez que ele tem a capacidade de prever onde ela estará no instante em que ela atingir o gol.

Buscando maneiras sistemáticas de se realizar previsões sobre dados sequenciais e aproveitando a estrutura de redes neurais artificiais, surgiram as redes neurais recorrentes.

Uma rede neural feedforward consegue mapear informações de entrada, processá-las e gerar uma saída, baseada nos pesos sinápticos das ligações entre seus neurônios, conforme citado em 2.1.2. Porém, ela é incapaz de armazenar e processar informações no tempo, característica essencial para realizar previsões e garantir uma **memória** de curto prazo. Esta característica pode ser adquirida se a informação que for transmitida de um neurônio de uma camada para o neurônio da camada seguinte também for retransmitida para ele mesmo (dá-se o nome de recorrência). Assim, o neurônio possui não apenas informações das entradas atuais, mas também informações das entradas anteriores.

Por isso, faremos o uso de redes neurais recorrentes, pois elas incluem laços (loops) em sua estrutura, capazes de processar tanto as informações do instante atual quanto as informações de instantes anteriores.

2.2.1 Definição

Segundo Haykins, “redes recorrentes são redes neurais com um ou mais laços de realimentação. A realimentação pode ser global ou local”. Existem diversas maneiras diferentes desta realimentação acontecer.

Se tomarmos como base uma rede neural multicamadas, formada basicamente por uma camada de entrada, uma camada oculta e uma camada de saída, podemos ter uma realimentação da camada de saída para a camada de entrada, uma realimentação da camada oculta para a camada de entrada ou até mesmo da saída para a camada oculta. Caso a rede multicamadas possua duas ou mais camadas ocultas, surgem ainda mais formas possíveis de se realimentar a rede, tornando sua arquitetura bastante diversificada.

A Figura 5 ilustra uma rede neural recorrente em que a saída realimenta a camada oculta.

Fonte 5 Haykins

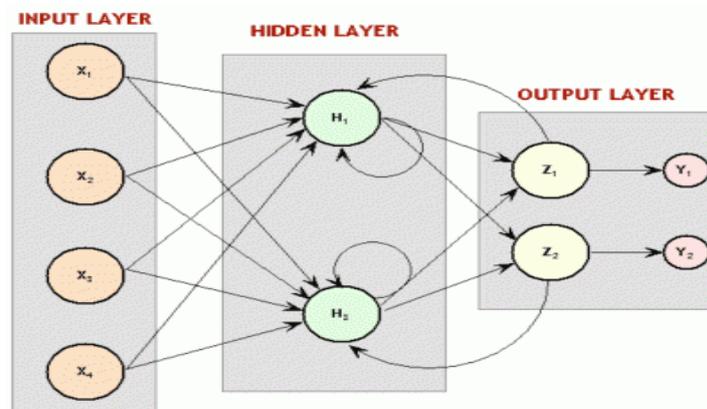


Figura 5 Exemplo de uma rede neural recorrente com realimentação das saídas para a camada oculta

2.2.2 Casos de Uso

- Entre as principais aplicações de redes neurais recorrentes, podemos citar:
- Reconhecimento de voz;
- Traduções;
- Legendas automáticas em vídeos (em tempo real), baseando-se nas palavras ditas anteriormente e tentando prever qual a próxima palavra;
- Formulação de frases descrevendo imagens;
- Previsão de valores de ações em bolsa de valores;
- Previsão de controle de estoque;
- Previsão da vazão afluente mensal de rios;

2.2.3 Arquitetura

Para um bom entendimento de como as redes neurais recorrentes trabalham ao longo do tempo, a imagem abaixo traz uma ilustração de como a camada oculta do instante anterior está diretamente ligada à camada oculta do próximo instante.

Fonte 6 <https://iamtrask.github.io/2015/11/15/anyone-can-code-lstm/>

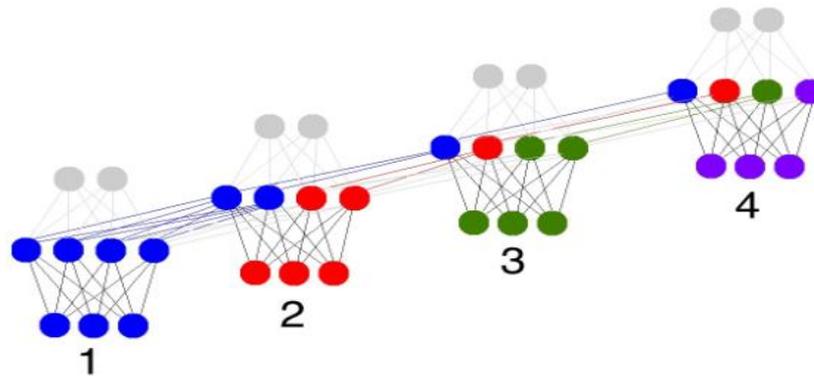


Figura 6 Rede neural recorrente em 4 períodos distintos

No instante inicial (instante 1) toda a informação que é passada para a camada de entrada é replicada na camada oculta. Já na segunda interação (instante 2), parte da informação que estava na camada oculta da primeira interação é repassada, através dos *nós de contexto*, para a camada oculta atual, e parte da informação desta mesma camada vem da camada de entrada. Assim, esta interação possui informações tanto da entrada atual quanto da entrada anterior. Esta capacidade de **memória** caracteriza as redes neurais recorrentes e as permite armazenar informações de períodos anteriores.

É exatamente esta característica desejada neste trabalho, uma vez que nosso objetivo é realizar uma previsão de demanda baseada em uma série temporal.

Existem diversas variações de arquitetura em redes neurais recorrentes. Dentre elas, podemos destacar duas: Elman e Jordan.

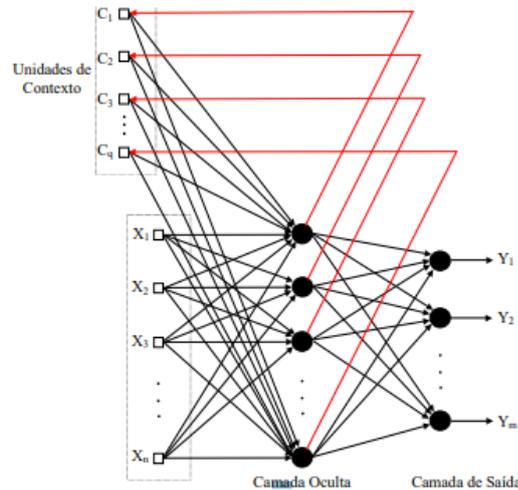
Redes recorrentes de Elman

Desde o início dos estudos sobre redes neurais recorrentes, foram criados diferentes tipos de redes neurais, entre elas a Rede de Elman, que apresenta uma *unidade de contexto*, que armazena (memoriza) as ativações anteriores e realimenta as camadas ocultas utilizando estes valores armazenados. A utilização de realimentação na camada oculta permite que todas as amostras já apresentadas à rede influenciem em sua resposta, enfatizando a influência sobre entradas mais recentes (Braga et al., 2007).

Nas redes de Elman existem camadas de entrada, camadas de saída e também camadas de contexto, cujo principal objetivo é memorizar as ativações de camadas anteriores e podem ser

consideradas como um atraso no tempo em um passo. Nas redes Elman, esta camada de contexto realiza a conexão entre camadas ocultas.

Figura 7 Estrutura de uma rede neural recorrente de Elman



Fonte 7 <https://imasters.com.br/data/um-mergulho-profundo-nas-redes-neurais-recorrentes>

Redes recorrentes de Jordan

Semelhante às redes de Elman, nas redes de Jordan a saída é copiada para a *unidade de contexto*. A maior diferença entre a topologia das redes Jordan e Elman é que nas redes Jordan a recorrência é feita das saídas para as entradas. Outra peculiaridade das redes Jordan é que o número de neurônios na unidade de contexto deve ser igual ao número de neurônios na camada de entrada.

2.2.4 Diversas Aplicações De Redes Neurais Recorrentes

Uma rede neural recorrente pode assumir diferentes formas diferentes, variando a quantidade de camadas de entrada, camadas ocultas e de saída. Cada tipo de rede neural recorrente é utilizado para um fim diferente. A Figura 8 representa as principais disposições que uma rede neural recorrente pode assumir.

Fonte 8 <http://karpathy.github.io/2015/05/21/rnn-effectiveness/>

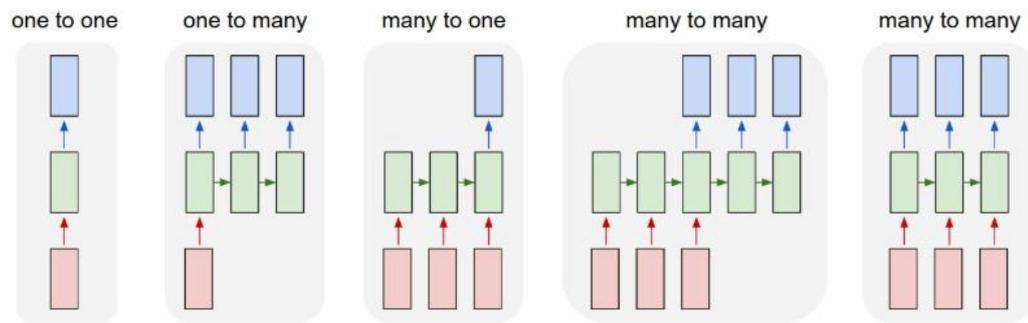


Figura 8 Diferentes tipos de aplicações usando redes neurais recorrentes

Nas figuras acima, as entradas estão representadas pelos blocos de cor rosa, as camadas ocultas estão sendo representadas pelos blocos em verde e as camadas de saída pelos blocos em azul.

No primeiro caso (**one-to-one**), observa-se que os sinais de entrada levam diretamente aos sinais da camada oculta que, por sua vez, transferem para a saída. Trata-se de uma rede neural feedforward clássica.

As redes **one-to-many** possuem apenas uma entrada para dados, mais de uma camada oculta com recorrência (os sinais da camada oculta são transferidos para as saídas e para os sinais da camada oculta no período de tempo posterior) e mais de uma saída. Um bom exemplo de uso deste tipo de rede seria a transcrição de uma imagem, uma vez que a entrada seria a própria imagem e o estado oculto seria lido várias vezes, representando cada palavra da descrição desta imagem, que seria enviada para a saída.

No caso **many-to-one**, os dados são passados para a entrada diversas vezes, esses dados são processados na camada oculta, mas geram apenas um resultado na saída. Um bom exemplo de uso deste tipo de rede é a análise de sentimentos em textos, cuja entrada seriam várias palavras e a saída um valor (positivo, negativo ou neutro).

Na aplicação **many-to-many** representada pela terceira imagem, os dados são lidos por alguns períodos de tempo antes de iniciar uma previsão, o que dá a este tipo de rede neural uma característica de defasagem temporal entre a entrada e a saída da previsão (“shift”). Bons exemplos seriam a tradução de áudios ou textos escritos em outra língua.

Por fim, há uma última aplicação **many-to-many** que é utilizada quando há a necessidade de ter várias entradas e saídas no mesmo período de tempo. Bastante utilizada em séries temporais, situações em que há a necessidade de realizar previsões para o período de tempo seguinte, dado o que aconteceu no período atual e nos períodos anteriores.

3 METODOLOGIA

3.1 PROBLEMA

Conforme já citado no capítulo 1, assim como a empresa utilizada neste trabalho, várias outras empresas não têm acesso à análise e previsibilidade de suas demandas e acabam tendo diversos problemas, como o armazenamento desnecessário de estoque ou a falta de um produto quando há uma demanda muito alta.

O presente trabalho tem por objetivo oferecer uma possível solução a estas empresas, desenvolvendo um algoritmo capaz de realizar uma previsão a uma taxa de aceitação aceitável e mostrar como as redes neurais recorrentes são capazes de realizar previsões a partir de dados históricos.

3.2 BASE DE DADOS

Os dados utilizados neste trabalho foram dados históricos de vendas de milho debulhado e sorgo, cedidos por uma empresa localizada em Goiânia-GO, que realiza a gestão comercial de uma outra empresa, localizada no município de Campinorte – GO, da qual foram coletados dados de vendas dos produtos desde o dia 19 de agosto de 2008 até o dia 26 de março de 2019.

Ao todo, foram coletados 3058 registros de vendas de milho debulhado e 1927 registros de vendas de sorgo, separados em apenas duas colunas: data de venda e quantidade vendida (em kg).

A fim de melhorar a precisão das previsões a serem realizadas, também foram extraídos dados do acúmulo mensal de chuva na região mais próxima onde atua a empresa, entre janeiro de 2009 a março de 2019, pelo INMET (Instituto Nacional de Meteorologia).

3.3 CARACTERIZAÇÃO E ANÁLISE DOS DADOS

A Figura 9 mostra a demanda diária de milho vendida pela empresa (em kg), durante o primeiro semestre de 2018.

Fonte 9 Próprio autor



Figura 9 Demanda diária de milho nos seis primeiros meses de 2018

É possível notar a inconstância dos valores quando os registros foram extraídos através da demanda diária e como ficam mais consistentes quando agrupados através da demanda mensal (Figura 10).

Fonte 10 Próprio autor



Figura 10 Demanda mensal de milho debruado, entre agosto de 2008 a março de 2019

Percebe-se ainda que existe uma completa ausência de suavidade no gráfico da demanda diária. Este fato é notado principalmente no último dia de cada mês, provavelmente causado pela realidade operacional da empresa, que deve utilizar o último dia para realizar um faturamento de pedidos feitos durante todo o mês.

Essa falta de suavidade no agrupamento diário evidencia a preferência pela escolha da utilização dos dados agrupados mensalmente.

A realidade do mercado em que a empresa está inserida, bem como seus processos diários não demandam uma predição com precisão diária, sendo completamente satisfatório que essa demanda seja realizada mensalmente. Portanto, o modelo de treinamento foi realizado utilizando dados mensais.

De maneira semelhante ao milho, analisando os dados de sorgo vendidos pela mesma empresa, no mesmo período de tempo (Figura 11), percebe-se a mesma inconstância dos dados. Portanto, a análise do sorgo também será realizada mensalmente (Figura 12).

Os dados de vendas mensais do milho debulhado e do sorgo estão nos anexos A e B, respectivamente.

Durante a análise dos dados não foi removida a tendência da curva.

Fonte 11 Próprio autor



Figura 11 Demanda diária de sorgo nos 6 primeiros meses de 2018

Fonte 12 Próprio autor



Figura 12 Demanda mensal de sorgo de agosto de 2008 a março de 2019

A fim de melhorar a análise e torná-la mais real, foi utilizada uma segunda análise com duas entradas para o algoritmo. Esta segunda entrada é o acumulado de chuva em Pirenópolis – GO (cidade com estação meteorológica mais próxima do estabelecimento da empresa detentora dos dados), durante o período de janeiro de 2009 a março de 2019, retirada do site do INMET.

Fonte 13 Próprio autor

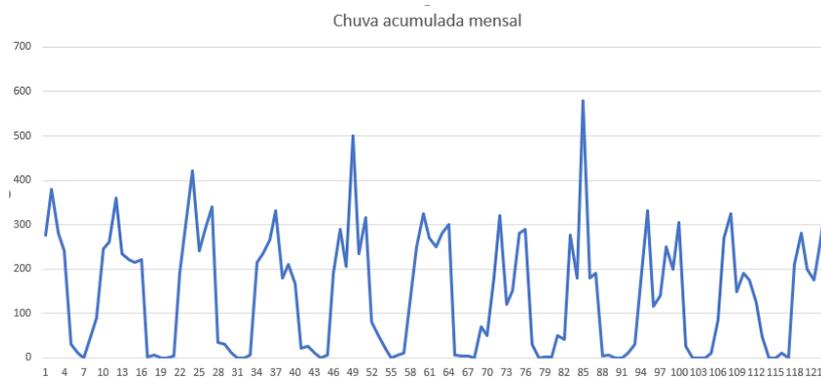


Figura 13 Chuva acumulada mensal de janeiro de 2009 a março de 2019 em Pirenópolis-GO

Foi repassado, pela empresa, que grande parte do volume de milho negociado por seus vendedores seriam para substituição da alimentação de animais. Sendo os principais animais que se alimentam desse milho e do sorgo os bovinos, seguido dos suínos. Esses produtos são ainda muito utilizados para fazer ração ou são fornecidos diretamente aos animais.

Nota-se ainda que nos períodos considerados de seca na região, principalmente entre junho e novembro, há uma elevação considerável da quantidade de milho vendida. Ao comparar os meses

anteriores e subsequentes a esse intervalo, evidencia-se ainda mais a utilização do acumulado de chuva mensal como uma segunda variável de entrada para prever, de maneira mais precisa, a demanda necessária dos produtos nos meses de interesse.

3.4 O ALGORITMO

Vale a pena enfatizar que, para a aplicação do presente trabalho, o tipo de rede neural recorrente que será utilizado será a **many-to-many**, explicada em 2.2.4, possuindo múltiplas entradas e múltiplas saídas.

Primeiramente, o algoritmo irá fazer a leitura de todos os dados de venda que estão referenciados nos apêndices A e B deste trabalho. O arquivo deve estar em formato *.CSV*, contendo três colunas: “MES”, “ANO” e “SUM”, cada coluna contendo seus respectivos dados referentes ao mês da venda, ano da venda e soma de todas as vendas realizadas naquele mês.

Em seguida, o algoritmo irá realizar o pré-processamento dos dados, coloca-los em um *DataFrame* da biblioteca *Pandas* do *Python*. A etapa de pré-processamento é responsável por criar diversos vetores que servirão de entrada para alimentar a nossa rede neural recorrente.

Por fim, o algoritmo realizará a previsão, treinando uma rede neural recorrente com 1 neurônio na camada de entrada, 64 neurônios na camada recorrente e 1 neurônio na camada de saída.

3.4.1 Pré-processamento e Transformação dos Dados

Inicialmente, os dados estão na forma de tabela e devem ser inseridos na rede neural no formato de vetores que representam sequências de vendas.

O primeiro passo, então, é colocar os dados na ordem crescente de mês e ano. Depois, criar um *tableau* cuja linha k possua os dados de venda no período inicial e a cada nova linha $(k+1)$ possua os dados de venda de k defasados em 1 período.

Desta forma, não existe mais a disposição em apenas uma coluna que represente a quantidade de milho ou sorgo vendidas no mês, mas sim uma tabela de sequências para treinamento da rede neural, cuja disposição é mostrada na Figura 14. O número de linhas sempre corresponderá ao total de registros presentes na base de dados.

Fonte 14 Próprio autor

	SUM	SUM1	SUM2	SUM3	SUM4	SUM5	SUM6	SUM7	SUM8	SUM9	...
0	15,500	33.251,780	87.408,250	59.954,620	158.296,090	150.453,580	214.452,380	245.411,260	137.706,860	251.150,040	...
1	33.251,780	87.408,250	59.954,620	158.296,090	150.453,580	214.452,380	245.411,260	137.706,860	251.150,040	173.250,960	...
2	87.408,250	59.954,620	158.296,090	150.453,580	214.452,380	245.411,260	137.706,860	251.150,040	173.250,960	120.954,280	...
3	59.954,620	158.296,090	150.453,580	214.452,380	245.411,260	137.706,860	251.150,040	173.250,960	120.954,280	117.590,800	...
4	158.296,090	150.453,580	214.452,380	245.411,260	137.706,860	251.150,040	173.250,960	120.954,280	117.590,800	83.653,650	...
5	150.453,580	214.452,380	245.411,260	137.706,860	251.150,040	173.250,960	120.954,280	117.590,800	83.653,650	128.253,630	...
6	214.452,380	245.411,260	137.706,860	251.150,040	173.250,960	120.954,280	117.590,800	83.653,650	128.253,630	109.475,170	...
7	245.411,260	137.706,860	251.150,040	173.250,960	120.954,280	117.590,800	83.653,650	128.253,630	109.475,170	174.174,320	...
8	137.706,860	251.150,040	173.250,960	120.954,280	117.590,800	83.653,650	128.253,630	109.475,170	174.174,320	266.099,820	...
9	251.150,040	173.250,960	120.954,280	117.590,800	83.653,650	128.253,630	109.475,170	174.174,320	266.099,820	431.686,140	...
10	173.250,960	120.954,280	117.590,800	83.653,650	128.253,630	109.475,170	174.174,320	266.099,820	431.686,140	373.170,220	...

Figura 14 Tableau após o pré-processamento dos dados de milho debulhado

3.4.2 Separação dos Dados Para Treino e Teste

A partir de cada linha do *tableau*, serão extraídas as variáveis independentes (colunas 0 a N-1, onde N representa o número de períodos escolhidos para realizar o shift) e as variáveis dependentes (colunas 1 até N), que são variáveis que definirão a porção do *tableau* que será utilizada para teste e treino.

Foram separadas 75 linhas para deste *tableau* para realizar o treinamento da rede neural e 37 linhas para o teste.

3.4.3 Processo de Treinamento Utilizando Redes Neurais Recorrentes

Com posse dos valores para treino e para teste da rede neural, o algoritmo passa para a criação da rede neural recorrente. Foi utilizada a biblioteca *Tensorflow* para a criação e treinamento da rede, que é composta por 1 neurônio na entrada, 64 neurônios recorrentes e 1 neurônio na saída.

A função de ativação que foi utilizada na camada recorrente foi a Exponential Linear Unit (ELU), cuja função é dada pela Equação 1 e sua representação gráfica pela Figura 15. Na camada de saída não foi utilizada nenhuma função de ativação.

$$R(z) = f(x) = \begin{cases} z, & z > 0 \\ \alpha \cdot (e^z - 1), & z \leq 0 \end{cases} \quad (1)$$

Fonte 15 <https://matheusfacure.github.io/2017/07/12/activ-func/>

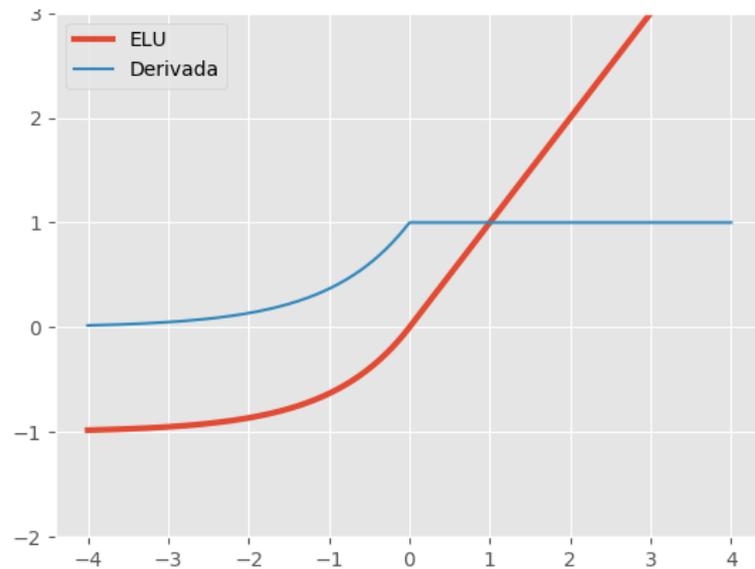


Figura 15 Comportamento da função de ativação ELU e sua derivada

No total, foram utilizadas 12000 iterações, utilizando lotes de 64 lotes cada. O tipo de otimização utilizada foi o AdamOptimizer e a cada 2000 iterações foi calculado um erro médio absoluto referente ao treinamento.

O erro médio absoluto talvez não seja a melhor opção. Utilizar a entropia cruzada pode ser mais eficiente para que o aprendizado ocorra.

Por fim, calculou-se o coeficiente de determinação (também denominado R^2) de toda a análise e os resultados serão discutidos nos capítulos que seguem.

3.4.4 Observações Adicionais Sobre o Procedimento

Foram realizadas, no total, 4 análises distintas utilizando o algoritmo:

- Análise utilizando dados de venda do milho debulhado, durante o período de agosto de 2008 a março de 2019.
- Análise utilizando dados de venda do milho debulhado junto aos dados de chuva acumulada mensal, durante o período de agosto de 2008 a março de 2019.
- Análise utilizando dados de venda de sorgo, durante o período de agosto de 2008 a março de 2019.
- Análise utilizando dados de venda de sorgo junto aos dados de chuva acumulada mensal, durante o período de agosto de 2008 a março de 2019.

Todos os experimentos apresentados durante este capítulo foram executados em uma máquina com sistema operacional Windows 10, processador Intel Core i5 2,7GHz e 8GB de memória RAM.

O algoritmo foi executado utilizando a linguagem Python e as bibliotecas Tensorflow, Pandas, Numpy e Matplotlib.

Ambos os testes foram feitos com os dois produtos principais comercializados pela empresa: o milho de bulhão e o sorgo.

4 RESULTADO

O algoritmo descrito no capítulo anterior foi executado em uma máquina com sistema operacional Windows 10, processador Intel Core i5, com frequência de 2,7GHz e 8GB de memória RAM e nos trouxe os seguintes resultados experimentais:

4.1 EXECUÇÃO DO ALGORITMO PARA OS DADOS DE VENDA DO MILHO DEBULHADO

Utilizando os dados de vendas de milho debulhado sem nenhuma outra variável em conjunto como entrada e utilizando 12 passos de tempo para treinamento, 107 registros para treinamento da rede neural, taxa de aprendizado de 0.001, obtivemos os seguintes resultados:

A Tabela 1 mostra o console da execução do algoritmo no terminal. Cada linha contém o valor do erro médio absoluto calculado a partir de 2000 iterações.

Iterações	Train MAE
0	163.661,80
2.000	5.312,16
4.000	5.169,61
6.000	5.300,73
8.000	4.471,80
10.000	3.993,37
12.000	3.860,33
TEST MAE	331.265,8

Tabela 1 Erro médio absoluto por quantidade de iterações para o milho debulhado

O último número representa o coeficiente de regressão, valor que varia de 0 a 1 e que representa o percentual de acerto entre os valores reais e os valores previstos pelo algoritmo.

A Figura 16 mostra o gráfico em linhas resultante da operação. Em amarelo está sendo mostrado o total de vendas realizadas por mês (valores reais) e em vermelho a previsão realizada pelo algoritmo.

Fonte 16 Próprio autor

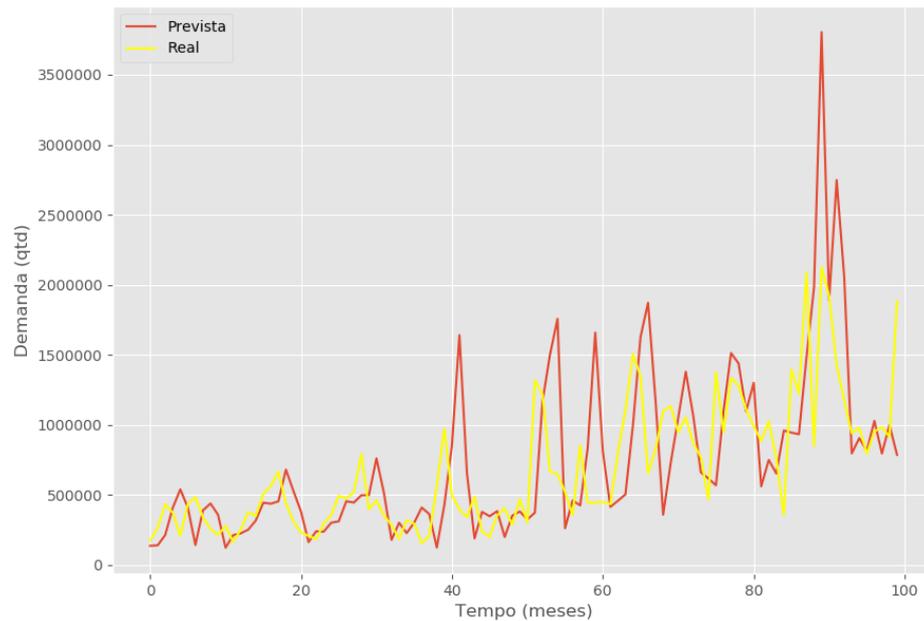


Figura 16 Resultado experimental do treinamento da rede neural recorrente utilizando dados de vendas do sorgo

Ao considerar série prevista em relação à série real, em sua totalidade foram observados resultados muito satisfatórios para a previsão conforme tabela mostrada na Tabela 2.

Erro Médio	Erro Médio Absoluto	Erro Percentual Médio	Erro Percentual Médio Absoluto
-25.070,68	25.070,68	-9,34%	28,75%

Tabela 2 Comparação de erros da previsão do milho com relação a demanda em todo período

Considerando que em cada saco de milho debulhado é armazenado cerca de 60 kg com um erro médio de -25.070,68 kg seria o equivalente a cerca de 417,84 sacos de milho a menos do que o realmente necessário na média de todo o período avaliado. Considerando que nos períodos finais houveram números muitos discrepantes dos padrões normais esse valor pode ser altamente satisfatório em um fluxo considerado mais normal.

Foi ainda amplamente notado que quanto mais brusca é a variação da demanda entre períodos curtos de tempo maior se torna o erro da previsão. Conforme a Figura 16, logo após o período de número 80 existem grandes picos seguidos de grandes vales na curva da demanda das vendas e conseqüentemente a curva da previsão ficou ainda mais distante do real. Isso pode ser causado

justamente devido a um aumento ainda maior de um efeito de aleatoriedade da demanda entre esses períodos.

Fonte 17 Próprio autor

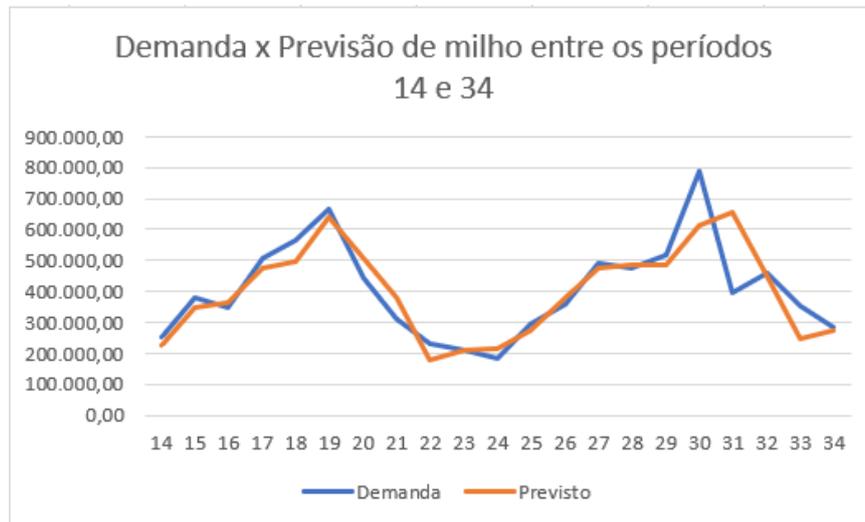


Figura 17 Gráfico de Previsão vs Demanda entre os períodos 14 e 34

De maneira oposta, os períodos finais tiveram um comportamento muito mais aleatório que o padrão geral dos demais períodos, resultando assim numa piora considerável da previsão geral conforme é mostrado na Figura 18.

Fonte 18 Próprio autor

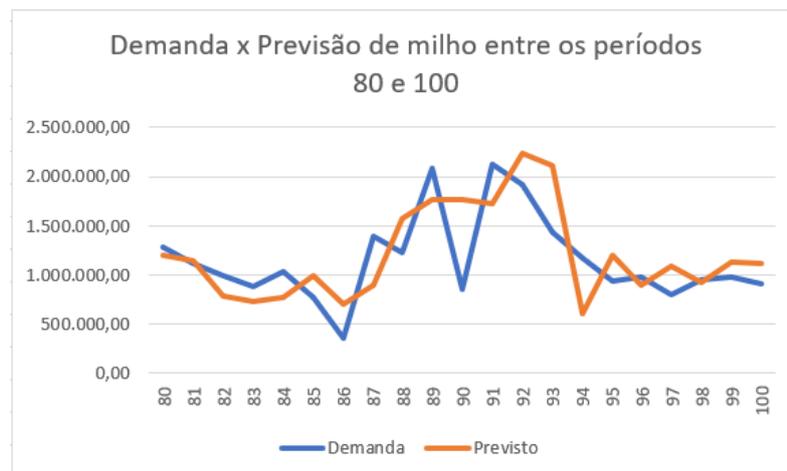


Figura 18 Gráfico de Previsão por demanda entre os períodos 80 e 100

Período	Erro Médio	Erro Médio Absoluto	Erro Percentual Médio	Erro Percentual Médio Absoluto
Completo	-25.070,68	25.070,68	-9,34%	28,75%
Entre 14 e 34	7.663,91	7.663,91	0,54%	13,75%
Entre 80 e 100	-57.437,34	57.437,34	-11,53%	31,49%

Tabela 3 Tabela comparativa entre erros de determinados períodos

Verificando a Figura 19 fica ainda mais claro o aumento do erro da previsão em períodos com comportamentos totalmente aleatórios e fora do padrão comum observado ao longo do tempo e a melhora da precisão em períodos com padrões mais lineares e sem muita aleatoriedade.

4.2 EXECUÇÃO DO ALGORITMO PARA OS DADOS DE VENDA DO SORGO

De maneira análoga ao experimento realizado com o milho, foi executado o algoritmo que calcula a previsão de vendas de sorgo.

A **Erro! Fonte de referência não encontrada.** mostra o console de execução do algoritmo a cada 2000 iterações, junto a seu erro médio absoluto.

Iterações	Train MAE
0	37.119,91
2.000	1.366,48
4.000	193,54
6.000	201,96
8.000	283,30
10.000	187,52
TEST MAE	59.037,01

Tabela 4 Erro médio absoluto por quantidade de iterações para o sorgo

Fonte 19 Próprio autor

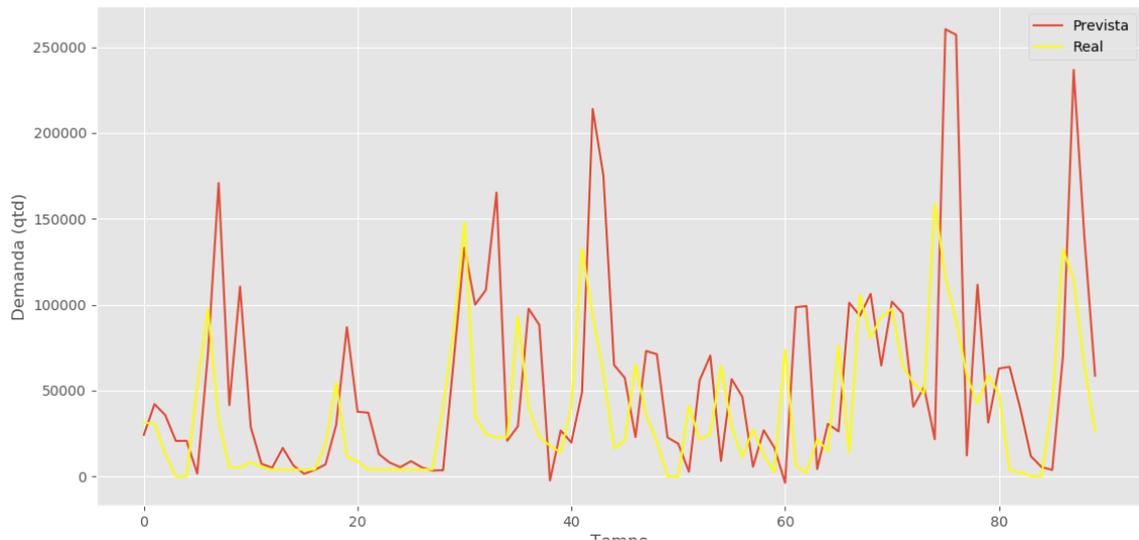


Figura 19 Resultado experimental do treinamento da rede neural recorrente utilizando dados de vendas do sorgo

A Figura 19 mostra que a previsão do sorgo acaba sendo pouco precisa, visto que o comportamento das vendas do mesmo é totalmente irregular, possuindo períodos que a quantidade vendida foi praticamente zero. Desta forma, foi considerado que o modelo proposto acaba sendo inviável para este tipo de comportamento que gera picos e vales enormes, resultando assim um erro percentual médio muito grande.

Ao recortar uma parte considerada mais estável seria possível chegar a um resultado um pouco melhor, porém isso seria maquiagem a realidade, sendo assim foi optado por considerar o modelo inviável para essa realidade.

4.3 COMPARATIVO ENTRE O MÉTODO INGÊNUO E REDES NEURASIS RECORRENTES

O método ingênuo é um tipo de previsão válida e de baixo custo, muito utilizada em empresas que não fizeram nenhum estudo sistemático de previsão anteriormente. Neste tipo de previsão, supõe-se que a previsão para o próximo período será igual ao último período.

Devido ao seu procedimento simples e de não necessitar um estudo sistemático sobre seus dados, muitos empreendedores adotam este tipo de método.

Neste subcapítulo será aplicado o modelo ingênuo sobre os dados do milho debulhado entre os meses 28 e 37 a fim de demonstrar a eficácia e as vantagens do método das redes neurais recorrentes em comparação com o método ingênuo em termos quantitativos e financeiro.

A quantidade real vendida entre os meses 28 e 37 são mostrados na Tabela 5.

Período	Demanda real (kg)
28	473.808,81
29	519.661,95
30	790.266,24
31	396.700,24
32	461.269,61
33	355.117,79
34	283.314,07
35	187.744,27
36	319.017,64
37	293.851,32

Tabela 5 Demanda de milho debulhado entre os os períodos 28 e 37

Levando em consideração que a previsão no período 't', usando o método ingênuo, é sempre igual à demanda no período passado, podemos criar uma nova coluna na Tabela 6, indicando a previsão para cada período, tendo como base a demanda real.

Período	Demanda real (kg)	Previsão usando método ingênuo (kg)
28	473.808,81	493.459,10
29	519.661,95	473.808,81
30	790.266,24	519.661,95
31	396.700,24	790.266,24
32	461.269,61	396.700,24
33	355.117,79	461.269,61
34	283.314,07	355.117,79
35	187.744,27	283.314,07
36	319.017,64	187.744,27
37	293.851,32	319.017,64

Tabela 6 Previsão utilizando o método ingênuo entre os períodos 28 e 37

Adicionando os dados da previsão, encontrados pelo algoritmo do presente trabalho, é possível calcular a diferença entre a demanda real e a prevista (em kg), tanto pelo método ingênuo quanto pelo algoritmo que utiliza as redes neurais recorrentes. Estes dados são mostrados na Tabela 7.

Período	Demanda real (kg)	Previsão usando método ingênuo (kg)	Previsão do algoritmo utilizando redes neurais recorrentes (kg)	Diferença entre o a demanda real e a previsão utilizando o método ingênuo (kg)	Diferença entre o a demanda real e a previsão utiizando redes neurais recorrentes(kg)
28	473.808,81	493.459,10	487.827,66	-19.650,29	- 14.018,85
29	519.661,95	473.808,81	486.028,20	45.853,14	33.633,75
30	790.266,24	519.661,95	611.804,06	270.604,29	178.462,18
31	396.700,24	790.266,24	655.194,50	-393.566,00	-258.494,26
32	461.269,61	396.700,24	447.267,10	64.569,37	14.002,51
33	355.117,79	461.269,61	246.357,16	-106.151,82	108.760,63
34	283.314,07	355.117,79	270.828,90	-71.803,72	12.485,17
35	187.744,27	283.314,07	244.466,53	-95.569,80	-56.722,26
36	319.017,64	187.744,27	279.043,62	131.273,37	39.974,02
37	293.851,32	319.017,64	384.371,25	-25.166,32	-90.519,93
Soma	-	-	-	293.851,32	-16.007,41

Tabela 7 Diferença entre o método ingênuo e o algoritmo do presente trabalho

O que se percebe é que se fosse utilizado o método ingênuo durante este período, faltaria 293.851,32 kg de milho em estoque, ao passo que utilizando o algoritmo do presente trabalho, sobrariam 16.007,41kg em estoque. Em porcentagem, utilizar o método de predição é 94,55% mais eficaz do que o método ingênuo neste caso.

Este valor pode ser refletido em reais quando adicionamos o preço da saca de milho debulhado de 60kg. A saca de 60kg está sendo vendida a uma média de R\$22,30. Portanto, o valor total que o comerciante que utilizasse o método ingênuo teria de comprar para ter seu estoque em dia seria de $\frac{293851,32}{60} \times 22,30 = R\$109.214,74$, ao passo que se ele utilizasse o algoritmo do presente trabalho, teria uma diferença de apenas $\frac{16007,41}{60} \times 22,30 = R\$5.949,42$.

Existiria, portanto, uma economia de R\$103.265,32 pelo uso do algoritmo do presente trabalho perante ao uso do método ingênuo.

5 CONCLUSÃO

Este trabalho teve o intuito de sugerir e estudar um modelo de previsão de demandas de quantidade de estoque para determinados produtos que são altamente comercializados por uma empresa de médio porte localizada no norte do estado de Goiás, através da técnica de redes neurais recorrentes.

Utilizando-se da ideia de que um algoritmo robusto de RNR poderia resultar em melhores previsões para a demanda dos produtos em um processamento relativamente rápido, sem necessitar grandes recursos computacionais e ainda possibilitar sua replicação de maneira rápida e satisfatória para diversos tipos de produtos e realidades.

Para a validação do modelo proposto foram realizados diversos experimentos empíricos, com dados reais de venda de milho debulhado e sorgo da empresa anteriormente mencionada e realizado ainda uma extensa análise dos resultados.

Foi observado, de modo geral, que o modelo proposto apresentou resultados altamente satisfatórios no âmbito prático, visto que a empresa a qual cedeu os dados não utiliza de nenhum estudo ou modelo atualmente para auxiliar na previsão de suas demandas, gerando diversos benefícios e vantagens competitivas perante a seus concorrentes.

De acordo com os resultados obtidos para o período estudado o erro percentual médio do modelo proposto para o milho debulhado foi de apenas -9,34%, já o erro percentual médio absoluto foi de 28,75%. O erro absoluto médio para este mesmo produto foi 25.070,68 kg. Levando em consideração que a média mensal comercializada foi de cerca de 667.020,87 kg, o erro é consideravelmente baixo sendo assim um resultado altamente satisfatório.

Foi notado ainda, que em períodos com uma demanda muito alta, totalmente fora do previsto, o modelo retorna um erro relativamente alto, mas que também se compensa em períodos mais estáveis com um erro extremamente baixo.

Além disso, ressaltamos que este trabalho abre uma enorme possibilidade de desenvolvimento acadêmico futuro para o aprimoramento e estudo do modelo aqui proposto e ainda vislumbra sua utilização como uma solução possível de entrar no mercado, trazendo assim diversas vantagens competitivas para as organizações que desejarem utilizá-lo.

Ainda devemos citar o benefício ambiental que o estudo aqui realizado pode trazer, evitando desperdícios de alimentos, otimização de ambientes de armazenamento e diminuição de poluentes ao otimizar a logística dos produtos estudados.

Ao pensar em um aprimoramento futuro, pode-se deslumbrar um maior estudo no tratamento dos dados para a entrada dos algoritmos de forma mais automatizada, visto que quando se trata de

redes neurais isso é um dos fatores mais importantes para que se tenha uma previsão mais correta e que ainda concentra grande parte do tempo do estudo do modelo.

Seria interessante ainda a realização de outros estudos estatísticos, de forma a comparar melhor o estudo realizado neste trabalho e analisar ainda se sua forma de replicação a partir de um modelo já pronto seria viável. Percebe-se que este estudo possibilita uma replicação altamente satisfatória, para diversos ambientes e realidades distintas, desde que o tratamento das consiga ser ainda mais otimizado.

**APÊNDICE A – DADOS DE VENDAS MENS AIS DE MILHO DEBULHADO ENTRE
AGOSTO DE 2008 E MARÇO DE 2019**

Mês	Ano	Quantidade vendida (kg)
8	2008	15,50
12	2008	33.251,78
1	2009	87.408,25
2	2009	59.954,62
3	2009	158.296,09
4	2009	150.453,58
5	2009	214.452,38
6	2009	245.411,26
7	2009	137.706,86
8	2009	251.150,04
9	2009	173.250,96
10	2009	120.954,28
11	2009	117.590,80
12	2009	83.653,65
1	2010	128.253,63
2	2010	109.475,17
3	2010	174.174,32
4	2010	266.099,82
5	2010	431.686,14
6	2010	373.170,22
7	2010	209.124,16
8	2010	435.048,27
9	2010	485.157,47
10	2010	340.026,34
11	2010	256.917,86
12	2010	214.480,53
1	2011	277.172,34
2	2011	164.353,22
3	2011	251.856,08
4	2011	377.330,69
5	2011	349.427,20
6	2011	507.657,05
7	2011	564.493,57
8	2011	664.960,48
9	2011	442.178,69
10	2011	308.771,45
11	2011	231.214,60
12	2011	208.039,50
1	2012	184.526,11
2	2012	293.401,13
3	2012	357.068,24

4	2012	493.459,10
5	2012	473.808,81
6	2012	519.661,95
7	2012	790.266,24
8	2012	396.700,24
9	2012	461.269,61
10	2012	355.117,79
11	2012	283.314,07
12	2012	187.744,27
1	2013	319.017,64
2	2013	293.851,32
3	2013	155.202,41
4	2013	205.820,56
5	2013	563.916,10
6	2013	974.506,06
7	2013	497.061,66
8	2013	395.219,57
9	2013	341.796,78
10	2013	487.938,22
11	2013	236.338,75
12	2013	199.746,40
1	2014	353.057,95
2	2014	404.697,99
3	2014	287.947,66
4	2014	469.383,03
5	2014	304.450,70
6	2014	1.317.423,61
7	2014	1.221.375,42
8	2014	666.135,37
9	2014	646.986,75
10	2014	521.880,09
11	2014	355.620,53
12	2014	853.108,17
1	2015	445.150,17
2	2015	443.563,37
3	2015	450.791,45
4	2015	434.507,00
5	2015	793.047,93
6	2015	1.106.774,12
7	2015	1.506.292,58
8	2015	1.347.501,95
9	2015	653.252,47
10	2015	825.497,47
11	2015	1.098.852,56
12	2015	1.133.470,70

1	2016	947.452,81
2	2016	1.052.655,18
3	2016	867.546,98
4	2016	771.357,19
5	2016	467.588,95
6	2016	1.377.072,60
7	2016	947.034,06
8	2016	1.335.445,53
9	2016	1.279.475,74
10	2016	1.111.176,27
11	2016	992.427,18
12	2016	885.271,91
1	2017	1.026.893,98
2	2017	763.936,78
3	2017	355.825,36
4	2017	1.395.073,38
5	2017	1.221.996,85
6	2017	2.087.839,77
7	2017	849.585,98
8	2017	2.124.442,08
9	2017	1.920.631,44
10	2017	1.429.057,89
11	2017	1.174.412,29
12	2017	941.397,73
1	2018	979.335,75
2	2018	794.623,25
3	2018	953.299,58
4	2018	984.111,37
5	2018	914.781,40
6	2018	1.881.644,83
7	2018	1.395.354,03
8	2018	1.018.070,39
9	2018	1.775.125,90
10	2018	1.186.365,75
11	2018	236.178,63
12	2018	2.364.725,26
1	2019	1.124.342,24
2	2019	1.066.222,97
3	2019	590.033,41

Tabela 8 Dados mensais de venda de milho debulhado

APÊNDICE B – DADOS DE VENDAS MENSAS DE SORGO ENTRE O PERÍODO DE

Mês	Ano	Quantidade vendida (kg)
1	2009	13617
2	2009	23191
3	2009	37849
4	2009	8848
5	2009	40954
6	2009	86370
7	2009	45942
8	2009	84078
9	2009	142614
10	2009	27923
11	2009	15367
12	2009	8535
1	2010	31253
2	2010	30596
3	2010	13162
4	2010	1
5	2010	1
6	2010	52757
7	2010	97618
8	2010	32749
9	2010	5144
10	2010	5247
11	2010	8306
12	2010	5419
1	2011	3929
2	2011	3879
3	2011	3879
4	2011	3879
5	2011	3879
6	2011	18739
7	2011	54660
8	2011	11479
9	2011	8723
10	2011	3984
11	2011	3984
12	2011	3984
1	2012	3984
2	2012	3984
3	2012	3984

4	2012	3984
6	2012	40579
7	2012	84961
8	2012	148175
9	2012	35186
10	2012	24418
11	2012	22760
12	2012	22760
1	2013	93034
2	2013	40024
3	2013	22845
4	2013	17783
5	2013	13890
6	2013	40574
7	2013	132586
8	2013	93187
9	2013	60146
10	2013	16358
11	2013	20913
12	2013	65150
1	2014	35503
2	2014	20192
4	2014	9
5	2014	5
6	2014	41081
7	2014	21328
8	2014	24451
9	2014	64428
10	2014	28224
11	2014	11232
12	2014	27225
1	2015	12323
2	2015	2428
3	2015	73769
4	2015	6465
5	2015	1984
6	2015	21539
7	2015	14569
8	2015	76385
9	2015	13981
10	2015	105719
11	2015	80631
12	2015	92827
1	2016	97723
2	2016	64411

3	2016	54302
4	2016	48225
6	2016	158939
7	2016	115600
8	2016	91191
9	2016	58631
10	2016	42381
11	2016	58765
12	2016	48041
1	2017	3639
2	2017	2118
4	2017	151
5	2017	161
6	2017	43023
7	2017	132278
8	2017	114525
9	2017	64603
10	2017	26470
11	2017	10671
12	2017	109629
1	2018	111341
2	2018	67642
3	2018	92371
4	2018	65530
5	2018	55003
6	2018	656316
7	2018	356113
8	2018	264861
9	2018	165638
10	2018	179264
11	2018	7597
12	2018	256465
1	2019	128890
2	2019	245291
3	2019	18354

Tabela 9 Dados mensais de venda de sorgo

APÊNDICE C – ALGORITMO UTILIZADO PARA O MILHO DEBLHADO

```

import tensorflow as tf # para Deep Learning
import pandas as pd # para manipulação de dados
import numpy as np # para manipulação de matrizes
from matplotlib import pyplot as plt # para gráficos
from tensorflow.contrib.rnn import BasicRNNCell # para RNRs

'''
    Leitura dos dados
'''
data = pd.read_csv('dados.csv') # leitura dos dados

'''
    Pré-processamento
'''
soma = data[['SUM']]
n_steps = 20 #definição a quantidade de períodos de tempo

for time_step in range(1, n_steps+1): #recria a tabela do excel com colunas defasadas
    soma['SUM'+str(time_step)] = soma[['SUM']].shift(-time_step).values
soma.dropna(inplace=True) #remove as linhas com valores nulos

X = soma.iloc[:, :n_steps].values #pega todas as linhas e 20 colunas para X
X = np.reshape(X, (X.shape[0], n_steps, 1)) #adiciona uma dimensão a mais para X
y = soma.iloc[:, 1:].values #pega todas as linhas e todas as colunas a partir de 1
para Y
y = np.reshape(y, (y.shape[0], n_steps, 1)) #adiciona uma dimensão a y

'''
    Separação dos dados para treino e teste
'''
n_test = 70 #variável que define quantos registros serão utilizadas no
teste
X_train, X_test = X[:-n_test, :, :], X[-n_test:, :, :]
y_train, y_test = y[:-n_test, :, :], y[-n_test:, :, :]

shuffle_mask = np.arange(0, X_train.shape[0]) # embaralhamento para utilizar o gradiente
descendente (estocástico)
np.random.shuffle(shuffle_mask)

```

```

X_train = X_train[shuffle_mask]
y_train = y_train[shuffle_mask]

'''
    Treinamento da rede neural
'''

n_inputs = 1                #número de neurônios na camada de entrada
n_neurons = 64              #número de neurônios na camada recursiva
n_outputs = 1              #número de neurônios na saída
learning_rate = 0.001      #taxa de aprendizado da rede

graph = tf.Graph()
with graph.as_default():   #inicializa o treino

    tf_X = tf.placeholder(tf.float32, [None, n_steps, n_inputs], name='X')
    tf_y = tf.placeholder(tf.float32, [None, n_steps, n_outputs], name='y')

    with tf.name_scope('Recurrent_Layer'):          #camada recursiva
        cell = BasicRNNCell(num_units=n_neurons, activation=tf.nn.elu)
        outputs, last_state = tf.nn.dynamic_rnn(cell, tf_X, dtype=tf.float32)

    with tf.name_scope('out_layer'):                #camada de saída
        stacked_outputs = tf.reshape(outputs, [-1, n_neurons])
        stacked_outputs = tf.layers.dense(stacked_outputs, n_outputs, activation=None)
        net_outputs = tf.reshape(stacked_outputs, [-1, n_steps, n_outputs])

    with tf.name_scope('train'):
        loss = tf.reduce_mean(tf.abs(net_outputs - tf_y))          #calcula o MAE
        optimizer = tf.train.AdamOptimizer(learning_rate=learning_rate).minimize(loss)

    init = tf.global_variables_initializer()

n_iterations = 10000
batch_size = 64

with tf.Session(graph=graph) as sess:
    init.run()

    for step in range(n_iterations+1):
        # cria os mini-lotes

```

```

offset = (step * batch_size) % (y_train.shape[0] - batch_size)
X_batch = X_train[offset:(offset + batch_size), :]
y_batch = y_train[offset:(offset + batch_size)]

# roda uma iteração de treino
sess.run(optimizer, feed_dict={tf_X: X_batch, tf_y: y_batch})

# mostra o MAE de treino a cada 2000 iterações
if step % 2000 == 0:
    train_mae = loss.eval(feed_dict={tf_X: X_train, tf_y: y_train})
    print(step, "\tTrain MAE:", train_mae)

# mostra o MAE de teste no final do treinamento
test_mae = loss.eval(feed_dict={tf_X: X_test, tf_y: y_test})
print(step, "\tTest MAE:", test_mae)

# realiza previsões
y_pred = sess.run(net_outputs, feed_dict={tf_X: X_test})

'''
Exibe o resultado na forma de gráficos
'''

sample = 10
plt.style.use("ggplot")
f = plt.figure(figsize=(10,7))
plt.plot(range(n_test), y_pred[:n_test,sample,0], label="Prevista")
plt.plot(range(n_test), y_test[:n_test,sample,0], color="yellow", label="Real")
plt.ylabel("soma (qtd)")
plt.xlabel("Tempo (meses)")
plt.legend(loc="best")
f.savefig("rnn_soma1.png")
plt.show()

from sklearn.metrics import r2_score
print(r2_score(y_pred=y_pred.reshape(-1,1), y_true=y_test.reshape(-1,1)))

```

BIBLIOGRAFIA

BALLOU, R. H. **Business logistics/supply chain management: planning, organizing and controlling the supply chain**. India: Pearson Education India, 2007.

CALDARELLI, C. E.; BACCHI, M. R. P. Fatores de influência no preço do milho no Brasil. **Nova Economia**, Belo Horizonte, 22, Jan/Apr 2012. 141-164.

CHOPRA, S.; MEINDL, P. **Gerenciamento da Cadeia de Suprimentos: Estratégia, Planejamento e Operação**. [S.l.]: [s.n.], 2003.

FACURE, M. Redes Neurais Recorrentes. **Matheus Facure**, 2018. Disponível em: <<https://matheusfacure.github.io/2017/09/12/rnn/>>. Acesso em: 20 nov. 2018.

JONES, M. T. Um mergulho profundo nas redes neurais recorrentes | iMasters. **iMasters**, 2017. Disponível em: <<https://imasters.com.br/data/um-mergulho-profundo-nas-redes-neurais-recorrentes/>>. Acesso em: 05 dez. 2018.

KOLEN, J. F. **Exploring the computational capabilities of recurrent neural networks**. Ohio: The Ohio State University, 1994.

MARTINS, P. G.; CAMPOS, P. R. **Administração de Materiais e Recursos Patrimoniais**. São Paulo: Saraiva, 2013.

PEINALDO, J. **Administração da Produção**. [S.l.]: [s.n.], 2007.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso., São Paulo, 2001.

RITZMAN, L. P.; KRAJEWSKI, L. J.; KLASSEN, R. **Foundations of operations management**. Toronto: Pearson Prentice Hall, 2004.

SEBRAE, S. B. D. A. À. E. E. P. E.-. **Causa Mortis**. São Paulo: Atlas, 2014.

SEGATTO, Ê. C.; COURY, D. V. Redes neurais artificiais recorrentes aplicadas na correção de sinais distorcidos pela saturação de transformadores de corrente. **Sba Controle & Automação**, São Paulo, v. 17, Dezembro 2006. ISSN 4.

THE Unreasonable Effectiveness of Recurrent Neural Networks. **Andrej Karpathy blog**, 2015. Disponível em: <<http://karpathy.github.io/2015/05/21/rnn-effectiveness/>>. Acesso em: 18 jun. 2019.