



UNIVERSIDADE FEDERAL DE OURO PRETO - UFOP
ESCOLA DE MINAS
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO



CAIO ADRIANO XAVIER DE SOUZA

**Previsão da Demanda de Materiais de Construção Utilizando Redes Neurais
Artificiais: Uma Comparação entre TensorFlow e PyTorch**

OURO PRETO - MG
2024

Caio Souza

**Previsão da Demanda de Materiais de Construção Utilizando Redes Neurais
Artificiais: Uma Comparação entre TensorFlow e PyTorch**

Monografia apresentada ao Curso de Graduação em Engenharia de Produção da Universidade Federal de Ouro Preto como requisito parcial para a obtenção do título de Engenheiro de Produção.

Professor orientador: Prof^o. Davi Neves Pavanelli

Professor coorientador:

**OURO PRETO – MG
2024**



FOLHA DE APROVAÇÃO

Caio Adriano Xavier de Souza

Previsão da Demanda de Materiais de Construção Utilizando Redes Neurais Artificiais: Uma Comparação entre TensorFlow e PyTorch

Monografia apresentada ao Curso de Engenharia de Produção da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Engenheiro de Produção

Aprovada em 30 de Julho de 2024

Membros da banca

Me. Davi Neves Pavanelli - Orientador (Universidade Federal de Ouro Preto)
Dr. Jorge Luiz Brescia Murta - Professor Convidado (Universidade Federal de Ouro Preto)
Dr. Gilberto Henrique Tavares Alvares da Silva - Professor Convidado (Universidade Federal de Ouro Preto)

Davi Neves Pavanelli, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 30/07/2024



Documento assinado eletronicamente por **Davi Neves Pavanelli, PROFESSOR DE MAGISTERIO SUPERIOR**, em 30/07/2024, às 10:35, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0748720** e o código CRC **D942AD9B**.

DEDICATÓRIA

À minha família pelo amor, apoio e confiança.

“O que todos devemos fazer é nos certificar que estamos usando a inteligência artificial de uma maneira que beneficie a humanidade, e não que a deteriore”

Tim Cook, CEO da Apple

RESUMO

O presente trabalho se propõe a explorar o potencial das redes neurais artificiais (RNs) para prever a demanda por materiais de construção. A pesquisa se concentra na comparação do desempenho de diferentes modelos de RNs, implementados nas bibliotecas TensorFlow e PyTorch, na tarefa de predição da demanda por cimento, concreto, encanamento, ferragens e pintura. Para tal, o estudo apresenta uma revisão da literatura sobre a indústria da construção civil e a relevância da análise da cadeia de suprimentos. A metodologia detalhada inclui a construção e treinamento de diferentes modelos de RNs, a pré-processamento dos dados e a avaliação do desempenho dos modelos. Os resultados obtidos indicam que os modelos que utilizaram TensorFlow com mais camadas ocultas tiveram o melhor desempenho entre os materiais. Logo, esse estudo demonstra a necessidade de teste de mais modelos e variações para poder alcançar resultados melhores e além disso uma superioridade da biblioteca do Google.

Palavras chave: Previsão de demanda; Redes neurais artificiais Indústria da construção civil; Materiais de construção; TensorFlow; PyTorch; Cadeia de suprimentos.

A B S T R A C T

This work aims to explore the potential of artificial neural networks (ANNs) for forecasting the demand for construction materials. The research focuses on comparing the performance of different ANN models, implemented in TensorFlow and PyTorch libraries, in predicting the demand for cement, concrete, plumbing, reinforcement, and paint. To this end, the study presents a literature review on the construction industry and the relevance of supply chain analysis. The detailed methodology includes the construction and training of different ANN models, data preprocessing, and evaluation of model performance. The results obtained indicate that the models using TensorFlow with more hidden layers performed the best among the materials. Therefore, this study demonstrates the necessity of testing more models and variations to achieve better results and also highlights the superiority of Google's library.

Keywords: Demand forecasting, artificial neural networks, construction industry, construction materials, TensorFlow, PyTorch, supply chain.

SUMÁRIO

1	INTRODUÇÃO.....	8
2	REVISÃO BIBLIOGRÁFICA	11
2.1	A indústria da construção civil	11
2.2	Cadeia de suprimentos	14
2.3	Redes neurais artificiais	16
2.3.1	Neurônios artificiais.....	16
2.3.2	O processo de aprendizado	17
2.3.3	A arquitetura das redes neurais.....	19
3	METODOLOGIA COMPUTACIONAL	20
3.1	A biblioteca TensorFlow	20
3.2	A biblioteca PyTorch.....	21
3.3	A biblioteca Keras	22
3.4	Utilizando uma rede neural para fazer análises	23
3.5	Os dados.....	24
3.6	Desenvolvimento do algoritmo.....	24
4	RESULTADOS E DISCUSSÃO.....	30
4.1	Análise da série temporal do Cimento.....	30
4.2	Análise da série temporal do Concreto	31
4.3	Análise da série temporal dos Encanamentos.....	31
4.4	Análise da série temporal da Ferragem	32
4.5	Análise da série temporal da Pintura	33
5	CONCLUSÕES GERAIS	33
	REFERÊNCIAS BIBLIOGRÁFICAS	36
	LISTA DE IMAGENS GERADAS PELOS MODELOS	39

1 INTRODUÇÃO

A análise da cadeia de suprimentos segundo Claude Machline (2011) é um campo de estudo que surgiu no final dos anos 1980 e se consolidou nos anos 1990, com o objetivo de integrar e otimizar os fluxos de materiais, informações e recursos entre os diversos agentes envolvidos na produção e distribuição de bens e serviços. Para Aragão(2004) essa abordagem permitiu uma visão mais ampla e estratégica da logística empresarial, que até então se concentrava principalmente no transporte, no armazenamento e na gestão de estoques.

A análise da cadeia de suprimentos teve um papel importante nas revoluções industriais, pois possibilitou a adaptação das empresas às mudanças nos padrões de demanda, na tecnologia, na concorrência e na globalização. Além disso, a análise da cadeia de suprimentos propiciou a elaboração da disciplina de planejamento, programação e controle da produção (PPCP), que visa coordenar as atividades operacionais dentro da empresa e entre os elos da cadeia, buscando atender aos requisitos de qualidade, custo e prazo dos clientes (GOMES et al., 2004). O PPCP é um dos pilares da gestão da cadeia de suprimentos e contribui para o aumento da eficiência, da flexibilidade e da competitividade das organizações.

Dentro do contexto atual a análise das cadeias de suprimento na construção civil utilizando redes neurais densas é um tema de grande relevância, pois a busca por eficiência e otimização dos processos é essencial para o sucesso das empresas do setor. As Cadeias de Suprimento(CS) desempenham um papel fundamental na indústria da construção, pois envolvem uma série de atividades complexas, como aquisição de materiais, logística, transporte e distribuição. Nesse sentido, o uso de Redes Neurais Densas(RND) como ferramenta de análise mostra-se promissoras, uma vez que essas técnicas podem capturar padrões e relações não triviais nos dados, possibilitando uma compreensão mais profunda e precisa das CS do setor. Portanto, este estudo tem como objetivo principal realizar uma análise abrangente dessas cadeias, explorando o potencial das RND como uma abordagem inovadora para obter insights valiosos e tomar decisões estratégicas.

No cenário atual da economia mundial, impulsionado pela evolução tecnológica e pela indústria 4.0, a gestão da CS tem se tornado cada vez mais digitalizada e orientada pela busca por maior agilidade, eficiência e assertividade. Essa transformação também se

faz presente na indústria da construção, que busca constantemente por melhorias em seus processos e práticas. De acordo com o BNDES (2019), a incorporação de novas tecnologias e a adoção de melhores práticas na gestão estão na agenda do setor de infraestrutura. A análise detalhada dessas transformações e a investigação do uso de RND como ferramenta de análise contribuem para o avanço e a modernização do setor, impulsionando a busca por soluções mais eficientes e inteligentes para os desafios.

As cadeias de suprimento na construção civil são complexas e envolvem múltiplos agentes, desde fornecedores de matérias-primas até os clientes finais. Os principais elementos dessas cadeias incluem aquisição de materiais, logística, armazenamento, produção, distribuição e gestão de resíduos. O fluxo de materiais ao longo dessas cadeias é significativo, com uma ampla variedade de produtos e componentes sendo transportados e utilizados em diferentes estágios dos projetos de construção. Além disso, o fluxo de informações desempenha um papel crucial, permitindo a coordenação eficiente entre os diversos participantes e a tomada de decisões fundamentadas. A compreensão dos principais elementos e fluxos de materiais e informações nas cadeias de suprimento da construção civil é essencial para o desenvolvimento de estratégias eficazes de gestão e otimização, visando melhorar a eficiência operacional, reduzir custos e garantir a satisfação dos clientes.

Os principais fatores que impactam diretamente sua eficiência e a eficácia são a complexidade, devido à natureza dos projetos de construção, que são únicos e envolvem diferentes etapas, materiais e recursos; a falta de transparência, dificultando o acompanhamento e o controle de informações cruciais, como prazos de entrega, qualidade dos materiais e conformidade regulatória; o gerenciamento de múltiplos fornecedores, uma vez que a construção civil requer uma ampla gama de materiais e componentes fornecidos por diferentes empresas. Logo, a análise aprofundada desses desafios é essencial para identificar oportunidades de melhoria e desenvolver estratégias eficazes para aprimorar a gestão das cadeias de suprimento na construção civil.

As Redes Neurais são compostas basicamente de modelos computacionais que simulam o funcionamento do cérebro humano e têm demonstrado um poderoso desempenho na análise de dados complexos. Esses modelos computacionais possibilitam explorar padrões, identificar relações não lineares e fornecer insights valiosos para aprimorar a eficiência e o desempenho das tais cadeias. Essa abordagem inovadora permite uma compreensão mais abrangente e precisa dos processos envolvidos,

possibilitando a tomada de decisões mais informadas e estratégicas. Portanto, a utilização de RND como ferramenta de análise das CS's, mais focado especificamente nas questões de demandas demonstra uma perspectiva promissora, abrindo novas oportunidades para melhorar a gestão e a operação, resultando em ganhos de produtividade e competitividade para o setor.

Logo, o objetivo geral deste trabalho é avaliar a eficácia das redes neurais na previsão de comportamentos de demanda na cadeia de suprimentos da construção civil, com ênfase na variação de preços de materiais de construção. Este estudo busca explorar como as redes neurais podem ser utilizadas como ferramentas precisas e eficientes para prever flutuações de preços, auxiliando na tomada de decisões estratégicas e na gestão de projetos no setor de construção. Compreender essas variações é crucial para a gestão eficiente de custos e prazos, impactando diretamente a viabilidade e o sucesso dos projetos de construção.

Para alcançar o objetivo geral, este trabalho estabelece objetivos específicos que guiarão a pesquisa em suas várias etapas. Primeiramente, será realizada uma revisão bibliográfica sobre cadeias de suprimento, a definição e funcionamento de redes neurais. Em seguida, em um dataset de estatísticas componentes e materiais de construção do Reino Unido serão identificadas séries temporais de demanda de materiais de construção, como canos, cimento, concreto, ferragem e pintura. Posteriormente, serão desenvolvidos e treinados modelos de redes neurais utilizando diferentes arquiteturas e bibliotecas, como PyTorch e TensorFlow. A pesquisa também se dedicará a avaliar o desempenho desses modelos, comparando sua precisão e capacidade de captar oscilações e tendências. Analisaremos as discrepâncias observadas entre as previsões dos modelos e as demandas reais, propondo melhorias nos modelos com base nos resultados obtidos. Por fim, este estudo pretende contribuir para a otimização da gestão de estoque e planejamento estratégico na construção civil, oferecendo insights valiosos para o setor.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo vamos elucidar os referenciais teóricos essenciais para a realização deste trabalho, iniciando com uma abordagem sucinta sobre a indústria da construção civil, salientando em seguida a relevância da análise da cadeia de suprimento correspondente a este setor, uma tarefa que hoje em dia pode ser executada de forma eficiente por redes neurais artificiais, sendo então este o nosso tema concludente.

2.1 A indústria da construção civil

Segundo Houaiss, a construção é o ato de reunir diferentes elementos para formar um todo, sendo assim caracterizada pela transformação de materiais isolados em grandes estruturas e isso por meio de material, equipamentos, ferramentas e mão de obra. Casarotto (1995) a classifica como sendo uma indústria de transformação com sistemas para produtos com posição fixa.

Cunha (2017) separa as construções como sendo obras Civas ou de Infraestrutura sendo as primeiras referentes a edifícios comerciais ou residenciais, como prédios e casas, e o segundo se refere a obras que possuem caráter social e alto impacto, ou seja, que visam trazer mais qualidade de vida para os cidadãos por meio de grandes e custosos empreendimentos.

As obras de infraestrutura podem ser divididas pelo seu tipo de estrutura, localidade e função, sendo elas obras de urbanização, como avenidas, praças e demais empreendimentos focados em atender necessidades urbanas, podem ser do sistema de água e esgoto, para coletar, tratar ou conduzir materiais líquidos, obras de movimentação de terra para nivelar ou preparar o terreno para outros empreendimentos e por último obras do sistema elétrico como linhas de transmissão, usinas de geração e sub-estações (Cunha et al. 2017).

O processo de construir pode ser dividido em três macro fases: planejamento, produção e operação, sendo eles representados respectivamente pelo motivo e necessidade da criação da nova estrutura, o que será a nova estrutura e como ela será feita; pela definição da data e da especificação de como fazer e pela parte de confecção. (Cunha et al. 2017).

Pode-se observar a importância da indústria de construção no Brasil pegando como base dados do Instituto Brasileiro de Geografia e Estatística (IBGE) da Pesquisa Nacional por Amostras de Domicílios(PNAD) que constatam que em 1989, 6,2% da População Economicamente Ativa (PEA) do país trabalhava no setor. Abrangendo principalmente mão de obra pouco especializada e de trabalhadores que não conseguiam espaço em outros mercados.

Outro fator que demonstra importância do setor dentro da economia nacional é que cerca de 7% do Produto Interno Bruto(PIB) nacional, 7,2% da PEA e 12,8% da produção industrial estão ligados direta ou indiretamente com esse setor, segundo dados da Sindicato da Indústria da Construção Civil no Estado de São Paulo(1991) e da Fundação João Pinheiro(1984).

É importante ressaltar que Martucci (1990), definiu com base em aspectos técnicos do setor da construção uma subdivisão nos respectivos sub-setores: materiais de construção e componentes, extração e transformação de recursos como cimento e tijolos, formado por diversas empresas de porte pequeno e médio e com poucas grandes e muito industrializadas; Produção de ferramentas, equipamentos, máquinas e suprimentos, participante de diversos setores sendo então a construção uma parcela de seu mercado, para tais produções é demandada muita tecnologia para produzir os tais equipamentos de grande porte; projeto, produção, e montagem de produtos finais, sub-setor referente ao próprio processo de construção, atua em diversas áreas rodovias, edificações, canais, sub-estações entre outros.

TABELA 4-2 – Comparação entre as várias divisões do setor de construção civil em sub-setores.

FUNDAÇÃO JOÃO PINHEIRO	IBGE – CENSO DA CONSTRUÇÃO	ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT – NBR 8950
<ul style="list-style-type: none"> • EDIFICAÇÕES (E) Residenciais Comerciais Institucionais Industriais Partes da edificação Serviços complementares à edificação • CONSTRUÇÃO PESADA (P) Infra-estrutura viária, urbana e industrial Obras de arte Obras de saneamento Barragens hidroelétricas, usinas atômicas • MONTAGEM INDUSTRIAL () Montagem de estrutura para instalação de indústrias Sistema de geração, transmissão e distribuição de energia elétrica Sistema de comunicações Sistema de exploração de recursos naturais 	<ul style="list-style-type: none"> • INCORPORAÇÃO DE IMÓVEIS E LOTEAMENTO 33.11 Incorporação de imóveis e loteamentos, quando associados à construção (E) 33.11 Incorporação de imóveis e loteamentos, quando não associados à construção (E) • OBRAS 33.21 Edificações (E) 33.22 Obras viárias (1) (P) 33.23 Grandes estruturas e obras de arte (2) (P) 33.24 Montagens industriais () 33.25 Obras de urbanização (P) 33.25 Obras de outros tipos • SERVIÇOS DA CONSTRUÇÃO 33.33 Construção de etapas específicas das obras (3) (E/P) 33.34 Serviços diversos (4) (P/E) 33.35 Outros serviços (5) 	<p>10. OBRAS DE EDIFICAÇÕES (E).</p> <p>11. Habitacionais</p> <p>12. Comerciais e/ou administrativas</p> <p>13. Industriais</p> <p>14. Culturais e desportivas</p> <p>15. Estações e terminais</p> <p>16. De assistência médico-social</p> <p>19. Outras obras de edificações</p> <p>20. OBRAS VIÁRIAS (P)</p> <p>21. Rodovia e infra-estrutura rodoviária</p> <p>22. Rodovia e infra-estrutura ferroviária</p> <p>23. Rodovia e infra-estrutura portuária</p> <p>24. Pistas e infra-estrutura aeroportuária</p> <p>Outras obras viárias</p> <p>OBRAS HIDRÁULICAS (P)</p> <p>Barragens</p> <p>Sistemas de saneamento</p> <p>Sistemas de irrigação</p> <p>Sistemas de drenagem</p> <p>39. Outras obras hidráulicas</p> <p>40. OBRAS DE SISTEMAS INDUSTRIAIS ()</p> <p>41. Implantação de indústrias de transformação</p> <p>42. Sistema de exploração e transporte de recursos naturais</p> <p>43. Sistema de geração e transmissão de energia</p> <p>44. Sistemas de comunicação</p> <p>49. Outras obras de sistemas industriais</p> <p>50. OBRAS DIVERSAS (P)</p> <p>51. Logradouros públicos</p> <p>52. Infra-estrutura urbana</p> <p>53. Paisagismo e ambientação urbana</p> <p>59. Outras obras de urbanização</p> <p>90. OBRAS DIVERSAS (P)</p> <p>91. Terraplenos</p> <p>92. Minas, poços e galerias</p> <p>93. Contenções</p> <p>99. Outras obras</p>
<p>OBSERVAÇÕES</p> <p>ferrovias, aeroportos, portos, instalações portuárias, canais, rodovias, terminais rodoviários, pontes, viadutos, túneis, usinas hidroelétricas, termoeletrônicas</p> <p>armações, formas, concretagem, instalações prediais, montagem de estrutura pré-moldada, pavimentação de estradas e vias urbanas, preparação de leitos de vias férreas, serviços geotécnicos, terraplanagem, sinalização de tráfego</p> <p>demolições, manutenção de rede de água, esgoto e galerias pluviais, urbanização e paisagismo</p> <p>outros serviços não especificados para complementação de execução, manutenção e reparação de outros tipos de obras</p>		

Fonte: PICCHI (1993)

Principais insumos usados na construção SEGUNDO PROCHNIK (1986).



2.2 Cadeia de suprimentos

Segundo BOWERSOX (2014), toda organização independente do seu setor de atuação depende da compra de materiais, serviços e suprimentos para apoiar as suas respectivas operações e dentro da chamada, Era da Informação, anos do final do século XX e início do XXI, a conectividade entre os agentes comerciais alterou e impulsionou as relações de compra e colaboração.


Esse conjunto de diferentes organizações unidas e trabalhando de forma cooperativa visando o desenvolvimento de produtos e serviços para os consumidores é o conceito de Cadeia de Suprimentos (BRISCOE; DAINTY, 2005).

Mesquita e Castro (2008) interpretam que a Cadeia de Suprimentos (CS) “compreende o planejamento e o controle de todas as operações incluídas nas atividades de suprimento e compras, transformação e todas as atividades logísticas de distribuição física dos produtos”. Sendo o elo de conexão das áreas das empresas. E segundo Magalhães (2015) pode ser a chave para uma estratégia de sucesso.

Para Haga (2000), dentro da construção civil a gestão dos suprimentos é de suma importância devido ao alto valor financeiro do empreendimento, tendo-se em vista o grande volume de matérias primas necessárias e seu custo elevado e com uma boa gestão é possível aumentar a eficiência do empreendimento cortando os custos de desperdícios e/ou desnecessários.

Tem ocorrido uma mudança da visão do setor de compras para realmente uma Gestão da Cadeia de Suprimentos (GCS) onde as relações estão se tornando menos transacionais, onde o comprador só quer adquirir o maior número de produtos pelo menor preço, e mais focadas em relacionamentos, visões compartilhadas, longevidade e ganhos bi-laterais. (BAILY, 2000)

Figura 1 - Relacionamento transacional



Fonte: Baily (2000)

Segundo HAGA (2000) as funções mais frequentes de Gestão de materiais dentro da CS são: Gestão de Suprimentos, estudo de estoque, planejamento de compras, estratégia de pedido, processamento e controle de compras, comunicação entre áreas e atividades, recebimento, acompanhamento de dead-lines das atividades; Controle de Qualidade, definição de materiais, aprovação das compras; Aquisição, compras, contratação de terceirizados, monitoramento de pós-pedido, avaliação de fornecedores, pesquisas de mercado; Controle dos dados dos fornecedores, atualização das informações; Expedição, relatar e projetar situação de entregas; Inspeção, testes de qualidade, inspeção da estrutura local; Transporte, planejamento de entrega, inspeção de remessas, efetuação do transporte, monitoramento de rota, inspeções de segurança do transporte e do cumprimento de dead-lines; Recebimento, realizar e relatar recebimentos; Armazenamento, definição de locais de docas e estocagem, cuidar da segurança e conservação dos materiais, movimentações de carga; Controle de Estoque, requisição de materiais, validação do volume, acompanhamento de volume e rotação de estoque.

O Gerenciamento da Cadeia de Suprimentos (GCS), segundo Simchi-Levi, Kaminsky e Simchi-Levi (2003), possui extrema importância na geração de capital aos produtores, porém o tal possui alta complexidade devido a grande quantidade de participantes, aos interesses conflitantes, as diversas interações e o fluxo de insumos, mão de obra, informações e capital.

FORRESTER (1958) em Industrial Dynamics demonstrou a necessidade de interação e troca ativa de explicações entre players da cadeia, pois por meio de suas pesquisas identificou que as trocas de informações de forma incompleta/incorreta levaram danos reais em todos os níveis da cadeia e foram demandados meses até que os níveis de produção se realinhassem.


2.3 Redes neurais artificiais

Segundo John von Neumann (1948) Redes Neurais Artificiais (RNA) são algoritmos usado para grandes análises de dados e previsões onde diversos neurônios matemáticos são interconectados em formato de rede com o objetivo de mimetizar a forma de pensamento humano buscando a resolução de problemas complexos.

Tal processo se dá por meio de treinamento da rede e atribuição de pesos para cada informação e funções de ativação de forma a se encaixar dentro de um modelo matemático que se adapta de forma automática aos dados ao qual foi exposto e replicando o que aprendeu na etapa de aprendizado. (MCCULLOCH; PITTS, 1943)

2.3.1 Neurônios artificiais

É a unidade fundamental de uma RNA e foi inspirado no Neurônio Biológico (NB) com base no pensamento de que: “Se na natureza deu certo, deve dar certo nos computadores”. Ambos então possuem estruturas bem semelhantes como: Os pontos de entrada da informação, chamados de dendritos nos NB, os pontos de processamento, chamados de corpo celular nos NB, os pontos de saída que controlam qual e como a mensagem será transmitida, chamados de axônios nos NB e a informação a ser transmitida. (Moreira, 2013).



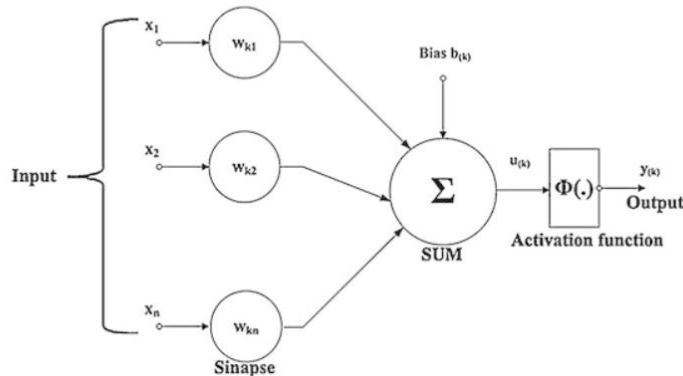
2.1 - Representação de Neurônio Natural

Para entendermos o Neurônio Artificial (NA), ou, Perceptron, temos que entender a sua estrutura, que segundo Warren McCulloch e Walter Pitts (1943) é dividida em:

- Sinais de Entrada { X_1, X_2, \dots, X_n }: Dados vindos do meio externo ou outros neurônios;
- Pesos Sinápticos { W_1, W_2, \dots, W_n }: São medidas de quão excitatórios são os estímulos enviados, o grau de relevância da informação para o resultado;
- Combinador Linear { Σ }: Combina o valor das entradas (X) com seus respectivos pesos (W) e o viés;
- Limiar de Ativação (threshold) { Θ }: Define quais os valores que o Combinador Linear gerou poderão gerar um disparo de ativação;
- Potencial de Ativação { U }: Diferença entre Σ e Θ . Caso seja maior que zero, gerará um potencial excitatório caso contrário gerará um valor inibitório;

- Função de Ativação { G } : Controla a saída do neurônio entre certas quantias e gera uma transformação, geralmente, não linear;
- Sinal de Saída { Y } : É o valor calculado pelo neurônio, podendo ser usado por outros neurônios ou como o resultado final da rede. (imagem 1).

Segundo McCulloch a representação matemática do neurônio biológico se dá da seguinte forma: x são as entradas, w são os pesos sinápticos, e y são as saídas. Logo se faz uma multiplicação matricial com as entradas $x = [x_{11}, x_{21}, x_{31}, \dots]$ que multiplicam $w = [w_0, w_1, w_2, \dots]$ e resultam e $y = [y_0, y_1, y_2, \dots]$ (Imagem 2, cap.2).



2.2 CHAGAS - Introdução às redes neurais densas

Segundo McCulloch a representação matemática do neurônio biológico se dá da seguinte forma: x são as entradas, w são os pesos sinápticos, e y são as saídas. Logo se faz uma multiplicação matricial com as entradas $x = [x_{11}, x_{21}, x_{31}, \dots]$ que multiplicam $w = [w_0, w_1, w_2, \dots]$ e resultam e $y = [y_0, y_1, y_2, \dots]$ (Imagem 3, cap.2).

$$Xw = y$$

$$\begin{bmatrix} 1 & x_{11} & \dots & x_{1d} \\ 1 & x_{21} & \dots & x_{2d} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & \dots & x_{nd} \end{bmatrix} \times \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_d \end{bmatrix} = \begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_n \end{bmatrix}$$

2.3 Representação da Operação matemática

2.3.2 O processo de aprendizado

Durante o processo de desenvolvimento de uma RNA é necessário treinar o algoritmo adicionando preliminarmente dados de entrada e suas respectivas saídas reais para que a rede descubra como se comportar, quais pesos sinápticos e bias que deve atribuir. Essa fase é chamada de treinamento da rede. (Slowik e Bialko, 2008)

Durante o treinamento se adiciona n dados de forma que w e b tenham valores arbitrários a princípio, como 0 e 0 ou qualquer outro valor. E se calcula o custo quadrático, que o resultado demonstra quão próximos as saídas calculadas y são das saídas reais. (Hegler et. al., 2009).

$$C(\mathbf{w}, \mathbf{b}) \equiv \left(\frac{1}{2n}\right) \sum_x \| \mathbf{y}(x) - \mathbf{a} \|^2$$

Por ter uma estrutura interconectada e com funcionamento feedforward, das primeiras camadas para as últimas, o erro de uma camada inicial é capaz de gerar diversos valores sucessivos relativos a ele, logo uma pequena alteração de w e b em um neurônio inicial é capaz de gerar grandes alterações na saída, para evitar grandes volumes de cálculos visando corrigir esses erros uma forma encontrada por Paul Werbos foi o backpropagation criado por Seppo Linnainmaa (1970) função que se calcula a derivada parcial do erro em relação a um peso.

$$\frac{\partial E}{\partial w_{i,j}} = \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial net_j} \frac{\partial net_j}{\partial w_{i,j}}$$

Regra da cadeia: (Shang e Benjamin, 1996).

$$\frac{\partial error}{\partial w1} = \frac{\partial error}{\partial output} * \frac{\partial output}{\partial hidden2} * \frac{\partial hidden2}{\partial hidden1} * \frac{\partial hidden1}{\partial w1}$$


Após o cálculo da derivada do erro se calcula os novos pesos. O novo peso será igual ao peso antiga subtraído pela multiplicação da derivada encontrada pela taxa de aprendizagem. A taxa de aprendizagem é um pequeno valor constante usado apenas para esse propósito de correção. Como as correções são pequenas são necessárias diversas interações até que seja alcançado um peso capaz de prever assertivamente as saídas reais. (Rumelhart at al., 1986).

$$\mathbf{Novo\ Peso} = \mathbf{Peso\ Antigo} - \mathbf{Derivada} * \mathbf{Taxa\ de\ Aprendizagem}$$

Pode-se encontrar três tipos de valor na derivada, positivos negativos e 0, no primeiro caso o peso antigo está muito alto e será reduzido, no segundo está baixo e será acrescido e se for 1 a função custo está em um mínimo local e peso não será ajustado. (Rumelhart at al., 1986)

2.3.3 A arquitetura das redes neurais

Para abordar problemas de classificação mais complexos, é comum empregar redes neurais com múltiplas camadas de neurônios, como ilustrado.



2.4 Ilustração RN com 2 camadas - CHAGAS

Nesta arquitetura, os dados de entrada (X_1 e X_2) são processados sequencialmente por camadas de neurônios interconectados. Cada neurônio realiza uma combinação linear ponderada de suas entradas e aplica uma função de ativação não linear, introduzindo não linearidade na rede e permitindo a modelagem de relações complexas entre as variáveis.

As camadas intermediárias, denominadas camadas ocultas, extraem características cada vez mais abstratas dos dados à medida que a informação flui da camada de entrada para a camada de saída. A camada de saída produz a resposta final da rede, que pode ser uma classificação, um valor numérico ou outra representação desejada.

Além das redes feedforward, como a apresentada na Figura, existem redes neurais recorrentes, como as redes de Hopfield (1982), que possuem conexões retroalimentadas. Essas conexões permitem que a rede "memorize" informações anteriores, tornando-as adequadas para tarefas que envolvem sequências de dados, como o processamento de linguagem natural e séries temporais."

3 METODOLOGIA COMPUTACIONAL

O capítulo anterior apresentou o contexto da indústria da construção civil e a importância da análise da cadeia de suprimentos. Neste capítulo, detalharemos a metodologia computacional empregada para realizar essa análise de forma precisa e eficiente. A ferramenta central desta pesquisa são as redes neurais artificiais (RNs), capazes de identificar padrões complexos nos dados e realizar previsões.

Serão abordadas as bibliotecas Keras, PyTorch e TensorFlow, amplamente utilizadas no desenvolvimento e treinamento de RNs. Explicaremos como essas bibliotecas foram empregadas para construir e treinar a rede neural utilizada neste trabalho. Além disso, detalharemos os dados utilizados para treinar e validar o modelo, assim como os processos de processamento e aplicação das RNs. Por fim, serão apresentados os detalhes da arquitetura da rede neural escolhida, incluindo o número de camadas, neurônios por camada e as funções de ativação utilizadas.

3.1 A biblioteca TensorFlow

Desenvolvido pela Google Brain Team sob liderança de Jeff Dean, juntamente com o engenheiro de software do Google, Rajat Monga, o TensorFlow é uma biblioteca de software de código aberto para aprendizado de máquina e inteligência artificial.

A designação "TensorFlow" é derivada da operação matricial tensor, amplamente empregada em diversos domínios matemáticos e físicos para o tratamento de informações pluridimensionais. No contexto de um modelo de aprendizagem de máquina, o TensorFlow adota o tensor como a principal ferramenta de representação dos dados, o que justifica a denominação.

A TensorFlow(TF) é constituído por diversos componentes que possibilitam a construção e execução de modelos de aprendizagem de máquina. Entre os componentes principais destacam-se:

- **Tensores:** correspondem aos dados fundamentais do TF. Tratam-se de arrays multidimensionais contendo valores numéricos que representam as entradas, saídas e parâmetros dos modelos de machine learning. Os tensores podem apresentar diferentes tipos, formas e dimensões.
- **Variáveis:** configuram-se como tensores especiais que armazenam e atualizam os valores dos parâmetros dos modelos durante o treinamento. As variáveis são

inicializadas com um valor inicial e podem ser modificadas por meio de operações de atribuição.

- Operações: consistem em funções que realizam cálculos matemáticos ou lógicos sobre os tensores. As operações podem utilizar um ou mais tensores como entrada e produzir um ou mais tensores como saída.
- Grafos: correspondem a estruturas de dados que representam o fluxo de dados e as dependências entre as operações e os tensores. Os grafos viabilizam a execução paralela e distribuída dos modelos de aprendizagem de máquina.
- Sessões: configuram-se como objetos que gerenciam o contexto de execução dos grafos. As sessões permitem a alocação de recursos (como memória e dispositivos) e a execução das operações presentes nos grafos.

3.2 A biblioteca PyTorch

PyTorch é uma biblioteca de código aberto baseado na linguagem de programação Python, desenvolvido pela equipe do Facebook e lançado em setembro de 2016 para simplificar o processo de criação de modelos de aprendizado de máquina. Uma das principais vantagens do PyTorch é a sua capacidade de construir modelos dinâmicos, o que significa que é possível definir o grafo computacional em tempo de execução, o que torna o processo de desenvolvimento mais flexível e eficiente. Além disso, o PyTorch é altamente otimizado para trabalhar com GPUs, permitindo que os usuários aproveitem a potência do hardware de aceleração para treinar seus modelos mais rapidamente.

Essa biblioteca possui diversos módulos voltados para o desenvolvimento de modelos de aprendizado de máquina como:

- `torch.nn`: Fornece diversas classes para definir e treinar redes neurais, incluindo camadas, funções de ativação, funções de perda e otimizadores.
- `torch.optim`: Auxilia na implementação de diversos algoritmos de otimização, incluindo o Gradiente Descendente Estocástico (SGD), Adam e Adagrad.
- `torch.utils.data`: Fornece classes para carregar e manipular dados de treinamento e validação. Inclui classes para carregar dados de imagens, texto e outros formatos.
- `torchvision`: Fornece modelos pré-treinados para classificação de imagens e detecção de objetos, bem como conjuntos de dados comuns, como o conjunto de dados ImageNet.
- `torch.autograd`: Responsável pela computação automática de gradientes. Isso permite que o PyTorch faça o backpropagation e atualize os parâmetros da rede neural durante o treinamento.

- `torch.utils`: este módulo fornece várias ferramentas úteis para o treinamento de modelos de aprendizado de máquina, incluindo ferramentas para salvar e carregar modelos e implementações de treinamento distribuído.

3.3 A biblioteca Keras

Desenvolvida em 2015 por François Chollet, Keras, é uma biblioteca de aprendizado profundo de código aberto para criação de modelos de redes neurais, desenvolvida em Python e posteriormente adaptada em duas versões para R, `kerasR` por Taylor Arnold e outra `keras` própria do software RStudio. É uma das bibliotecas mais populares para criar modelos de deep learning, pois é fácil de usar e tem suporte para GPUs.

Keras suporta arquiteturas de redes neurais convolucionais, recorrentes e de memória profunda, bem como modelos de aprendizado de máquina supervisionado. Ele também oferece métodos de treinamento eficientes para modelos complexos, como modelos de aprendizado profundo. Além disso, a biblioteca Keras permite que você crie modelos de deep learning usando APIs diferentes, como as APIs do TensorFlow, CNTK e Theano.

Para utilizar uma das bibliotecas deve-se inicialmente instalar as mesmas no console em conjunto do TensorFlow, exemplo em imagem a seguir.

Para exportar um conjunto de dados para o Keras, é necessário primeiro converter seus dados em um formato que o Keras seja capaz de ler, como CSV, TFRecord e HDF5. Uma vez que seus dados estão no formato adequado, você pode carregá-los para o Keras usando uma das APIs fornecidas.

Para se dar início ao processo de criação das RN's esses dados devem então ser transformados em tensores, objetos algébricos com um número arbitrário de dimensões (D), essas dimensões variam de quantidade de acordo com o problema trabalhado.

3.4 Utilizando uma rede neural para fazer análises

Diante da complexidade e dos desafios enfrentados na gestão da cadeia de suprimentos, as redes neurais surgem como uma abordagem promissora para melhorar a eficiência e a tomada de decisões nesse contexto.

Cada um dos materiais será explorado por diversas abordagens utilizando redes neurais, os resultados das previsões obtidas e os benefícios proporcionados então serão analisados e debatidos. Ao final deste trabalho, espera-se fornecer uma visão abrangente de algumas possibilidades e vantagens da utilização de redes neurais na análise da cadeia de suprimentos, assim como vantagens de cada arquitetura.

As redes neurais oferecem uma abordagem sofisticada e avançada para modelar padrões complexos e não lineares dos dados históricos de demanda, considerando fatores sazonais, tendências e efeitos promocionais. Isso resulta em previsões mais precisas e confiáveis, permitindo às empresas melhorar a precisão dos níveis de estoque, otimizar a produção e alocar recursos de forma mais eficiente. Além disso, a capacidade das RN's de se adaptar a mudanças nas condições do mercado e de modelar interações complexas entre variáveis torna-as uma ferramenta valiosa para lidar com a natureza dinâmica da demanda na cadeia de suprimentos.

Outro aspecto relevante é o uso das redes neurais para a previsão de leadtime, que representa o tempo necessário para que um pedido seja entregue após sua realização. Dessa forma, tendo maior ciência de suas demandas, as empresas podem antecipar a ocorrência de oscilações no mercado, possibilitando uma maior facilidade de tomada de medidas corretivas adequadas e melhorando a eficiência operacional. E uma possível aplicação futura, das redes neurais na previsão de leadtime poderia oferecer uma abordagem avançada e poderosa para lidar com a incerteza e a variabilidade inerentes aos processos de cadeia de suprimentos, contribuindo para um planejamento mais eficiente e um melhor desempenho geral.

Com base nessas previsões, as empresas podem otimizar seus níveis de estoque, evitando a escassez ou o excesso, reduzindo custos e melhorando a eficiência operacional. Podem também ser empregadas para determinar pontos de reposição ideais, estratégias de reabastecimento e alocação de estoque entre diferentes localidades. Essa abordagem oferece uma visão mais abrangente e precisa da dinâmica dos estoques, permitindo às

empresas tomar decisões embasadas e reduzir os riscos associados à gestão de estoques na cadeia de suprimentos.

3.5 Os dados

Os dados utilizados são um conjunto de planilhas chamadas de Building Materials and Components statistics (Estatísticas de Materiais e Componentes de Construção), elas contém dados de mensais, 2018 a 2023, sobre índices de preços, tijolos, cimento e blocos de concreto; e dados trimestrais sobre areia, cascalho, ardósia, telhas de concreto para telhados e concreto pré-misturado.

Os mesmos, foram adquiridos por meio do portal governamental do Reino Unido dedicado à disponibilização de dados abertos do governo, <http://www.data.gov.uk/>. Lançado em 2010, o site, tem como objetivo principal fornecer acesso livre e aberto a uma ampla variedade de conjuntos de dados do governo britânico permitindo que indivíduos, pesquisadores, empresas e organizações utilizem e analisem as informações para diferentes propósitos.

O responsável pela publicação foi Department for Business and Trade (Departamento de Negócios e Comércio), como objetivo promover o crescimento econômico, melhorar o acesso ao financiamento, promover os negócios britânicos globalmente, promover mercados competitivos, legislar sobre serviços públicos prioritários, revisar a legislação relacionada à União Europeia, além de garantir a segurança econômica e resiliência da cadeia de suprimentos.

3.6 Desenvolvimento do algoritmo

O objetivo desta pesquisa foi analisar o desempenho de redes neurais na previsão de comportamentos na cadeia de suprimentos da construção civil, mais especificamente em relação à variação de preços de materiais de construção. A cadeia de suprimentos desempenha um papel crucial no setor da construção civil, impactando diretamente os custos e prazos de projetos. Portanto, compreender e prever as flutuações de preços dos materiais é fundamental para uma gestão eficiente e estratégica nesse contexto.

Nesse sentido, as redes neurais surgem como uma ferramenta promissora para análise e previsão de séries temporais, devido à sua capacidade de aprender padrões complexos e realizar estimativas precisas com base em dados históricos. A utilização dessas redes nessa pesquisa possibilitou a criação de modelos que podem auxiliar na tomada de decisões relacionadas à aquisição e gestão de materiais na construção civil, contribuindo para o planejamento estratégico e otimização dos processos na cadeia de suprimentos.

No desenvolvimento deste projeto, foram explorados dois tipos de redes neurais para análise da cadeia de suprimentos na construção civil. Sendo então, desenvolvidos quatro modelos no total, diferenciados pela arquitetura e pelas bibliotecas utilizadas: PyTorch(TK) e TensorFlow(TF).

O primeiro tipo de rede neural consiste em um modelo com uma camada de entrada contendo um neurônio, uma camada interna com dez neurônios e uma camada de saída com um neurônio. Essa arquitetura é caracterizada por sua simplicidade, apresentando um número reduzido de neurônios em comparação com a segunda rede.

O segundo tipo de rede neural adota uma estrutura mais complexa, composta por uma camada de entrada com um neurônio, uma primeira camada interna com dez neurônios, uma segunda camada interna com quinze neurônios, uma terceira camada interna com dez neurônios e, por fim, uma camada de saída com um neurônio.

Tendo em vista as bibliotecas e o número de camadas utilizadas, os modelos então foram apelidados da seguinte forma: TF(I-10-O), TF(I-10-15-10-O), TK(I-10-O) e TK(I-10-15-10-O).

Com base nos dados coletados e explicados no capítulo anterior foram selecionados índices de preços de cinco materiais-chave: canos, cimento, concreto, ferragem e pintura. Essas variáveis foram escolhidas com o intuito de limitar o escopo do estudo e focar em elementos essenciais para a construção.

Os valores dessas variáveis ao longo da série histórica foram agrupados em um arquivo CSV, mantendo o formato temporal, ou seja, preservando a ordem cronológica dos dados. Vale ressaltar que esses dados não passaram por processos de normalização ou transformação similar, sendo mantidos em sua forma original. Essa abordagem permite explorar diretamente as flutuações e padrões dessas variáveis ao longo do tempo,

fornecendo insights sobre as tendências e comportamentos da cadeia de suprimentos na construção civil.

Constam aqui um pseudocódigo, com foco em TF, que representa a estrutura básica dos modelos com uma camada interna de neurônios e outro pseudocódigo para modelos com três camadas internas de neurônios. Esplana-se também algumas das diferenças fundamentais entre essas abordagens, destacando suas implicações no desempenho e na capacidade de aprendizado dos modelos.

Importando bibliotecas: Nessa seção, foram importadas as bibliotecas necessárias para o projeto, como numpy, pylab, pandas e tensorflow/pytorch.

```
# Importando bibliotecas  
  
import numpy as np  
  
import pylab as pl  
  
import pandas as pd  
  
from tensorflow import keras as ks
```

Carregando os dados: É realizado o carregamento dos dados do arquivo "dados.csv" utilizando a biblioteca pandas. Os dados são armazenados em um DataFrame chamado "df". A coluna "Dates" do DataFrame foram convertidas em formato de data utilizando a função pd.to_datetime().

```
# Carregando os dados  
  
df = pd.read_csv("dados/dados.csv")  
  
tempo = pd.to_datetime(df["Dates"], format="%m-%y")
```

Preparando os dados de consumo de cimento: Os dados específicos de consumo da variável em análise são extraídos do DataFrame e armazenados em uma variável com nome traduzido para o português, no exemplo abaixo “cimento”.

```
# Preparando os dados de consumo de cimento  
  
cimento = df["Cement"]
```

Representando os dados em um gráfico: Essa seção envolve a visualização dos dados de consumo de cimento em um gráfico utilizando a biblioteca pylab. Os conjuntos de treinamento e teste são plotados no gráfico.

Representando os dados em um gráfico

plotar_dados(tempo, cimento)

Preparando os dados de entrada e saída: Os dados de consumo são divididos em duas partes: "xin" contendo os dados de entrada (consumo atual) e "xout" contendo os dados de saída (consumo seguinte). Isso é realizado utilizando indexação no array "cimento". Em Pytorch Os dados de treinamento são convertidos em tensores do PyTorch usando a função `tk.tensor()` e `reshape()`. E os tensores representam os dados de entrada (consumo atual) e dados de saída (consumo seguinte).

Preparando os dados de entrada e saída

xin = cimento[:-1]

xout = cimento[1:]

Construindo a rede neural: São definidos os números de camadas e neurônios em cada uma das camadas. EM TF se utiliza a biblioteca Keras e a função "construir_rede_neural()" e em TK usando a classe `Sequential()`

Construindo a rede neural

model = construir_rede_neural()

Compilando o modelo: O modelo da rede neural é compilado e ocorrem as definições do otimizador, "adam", e a função de perda, "mean_squared_error", para o treinamento da rede.

Compilando o modelo

compilar_modelo(model)

Treinando o modelo: o modelo é treinado utilizando a função "treinar_modelo". São realizados 100 treinamentos, utilizando os dados de entrada e saída para ajustar os parâmetros da rede neural. EM TK os dados utilizados são tensores, as previsões são calculadas pelo modelo usando o tensor de entrada, o erro é calculado comparando as previsões com o tensor de saída e é propagado de volta pelo modelo usando o método `backward()` e o otimizador ajusta os pesos do modelo usando o método `step()`.

Treinando o modelo

treinar_modelo(model, xin, xout)

Determinando o ajuste da rede neural: é feita uma previsão com base nos dados de entrada do treinamento utilizando a função "model.predict(xin)". O resultado é armazenado na variável "ajuste". Para PyTorch o cálculo automático de gradientes é desativado usando a função set_grad_enabled(), para evitar o acúmulo desnecessário de gradientes durante a etapa de inferência ou avaliação do modelo, economizando assim recursos computacionais e acelerando o processo de inferência. As previsões são feitas usando o modelo treinado e o tensor de entrada "in_tensor" e convertidas de tensores do PyTorch para arrays numpy.

```
# Determinando o ajuste da rede neural
```

```
ajuste = model.predict(xin)
```

Imprimindo os resultados do ajuste: Os resultados do ajuste são exibidos em um gráfico, comparando os dados de saída originais "xout" com as previsões da rede neural "ajuste".

```
# Imprimindo os resultados do ajuste
```

```
plotar_resultados(xout, ajuste)
```

Calculando a precisão do ajuste: A função "np.corrcoef()" é utilizada para calcular a precisão do ajuste comparando as previsões feitas pela rede neural (variável "ajuste") com os dados de saída originais (variável "xin"). O resultado é armazenado na variável "precisao_ajuste"("corr_p") e mesma é impressa na tela.

```
# Calculando a precisão do ajuste
```

```
precisao_ajuste = calcular_precisao(xin, ajuste) imprimir_resultado("Precisão do ajuste", precisao_ajuste)
```

Fazendo as previsões: EM TF foram feitas previsões com base nos dados de teste "ct_teste" utilizando a função "model.predict()". O resultado é armazenado na variável "previsoes". Na outra biblioteca, os dados de teste foram convertidos em tensores do PyTorch usando a função tk.tensor() e reshape(), as previsões feitas utilizando o modelo treinado e o tensor de entrada e então convertidas de tensores do PyTorch para arrays numpy.

```
# Fazendo as previsões
```

```
previsoes = model.predict(ct_teste)
```

Calculando a precisão das previsões: A função "calcular_precisao" ("np.corrcoef()") é utilizada novamente para calcular a correlação entre os dados de teste originais "ct_teste" e as previsões "previsoes". O resultado é armazenado na variável "corr_p14". Imprimindo os resultados das previsões. Os resultados das previsões são exibidos em um gráfico, comparando os dados de saída originais previsões da rede neural , além disso, são plotados os dados de teste e as previsões futuras no gráfico. E então, o programa é encerrado após a exibição dos resultados das previsões.

```
# Calculando a precisão das previsões
```

```
precisao_previsoes = calcular_precisao(ct_teste, previsoes)imprimir_resultado  
("Precisão das previsões", precisao_previsoes)
```

```
# Imprimindo os resultados das previsões
```

```
plotar_previsoes(xout, ajuste, ct_teste, previsoes)
```

```
# Fim do programa
```

4 RESULTADOS E DISCUSSÃO

Após a detalhada descrição da metodologia e a apresentação dos resultados obtidos na experimentação, este capítulo se dedica à análise e discussão dos resultados. A comparação entre os diferentes modelos de redes neurais, implementados nas bibliotecas TensorFlow e PyTorch, permitirá identificar qual arquitetura e hiperparâmetros se mostraram mais eficazes para a previsão da demanda por materiais de construção. As conclusões deste trabalho contribuirão para o avanço do conhecimento na área de previsão de demanda na indústria da construção civil, além de fornecer subsídios para a tomada de decisões mais assertivas pelos gestores da cadeia de suprimentos. Serão apresentadas as principais contribuições deste trabalho, bem como as limitações da pesquisa e sugestões para trabalhos futuros

4.1 Análise da série temporal do Cimento

TF(I-10-O) – (Figura 6, cap. 5)

Conseguiu se aproximar da demanda real, mas não conseguiu captar adequadamente todas as oscilações presentes nos dados reais. Em diversos pontos, a curva de previsão pelo modelo desvia-se da curva real, especialmente em momentos de alta variação de demanda.

TF(I-10-15-10-O) – (Figura 21, cap. 5)

Apresentou desempenho excelente, a curva prevista pela RN está tão próxima da curva real em parte dos pontos que acarretou em dificuldade de legibilidade do gráfico devido a sobreposição das linhas.”

TK(I-10-O) – (Figura 34, cap. 5)

A simplicidade do modelo não foi adequada para refletir a complexidade dos dados de demanda do cimento. Apesar das limitações, há um leve movimento crescente na curva prevista, indicando uma tentativa rudimentar de seguir a tendência geral.

TK(I-10-15-10-O) – (Figura 44, cap. 5)

Embora o modelo tenha subestimado significativamente o volume da demanda real, ele consegue seguir razoavelmente a forma da curva, capturando algumas das principais tendências e oscilações.

4.2 Análise da série temporal do Concreto

TF(I-10-O) – (Figura 9, cap. 5)

Este modelo apresentou uma performance insatisfatória, com previsões que não se aproximam da demanda real.

TF(I-10-15-10-O) – (Figura 24, cap. 5)

Alcançou um ótimo desempenho, capturando efetivamente as oscilações e tendências da demanda real. As discrepâncias são mínimas e ocorrem principalmente em pontos de alta variação.”

TK(I-10-O) – (Figura 36, cap. 5)

A curva prevista pela rede neural permanece constantemente muito abaixo da curva real, falhando em capturar as tendências e oscilações presentes nos dados reais assim como seu par de mesmas configurações da biblioteca TensorFlow.

TK(I-10-15-10-O) – (Figura 46, cap. 5)

Apresentou performance insatisfatória em termos de volume de demanda, com previsões significativamente abaixo da demanda real. No entanto, a RN demonstrou capacidade de captar as variações gerais de tendência, mas sem muita assertividade.

4.3 Análise da série temporal dos Encanamentos

TF(I-10-O) – (Figura 3, cap. 5)

Demonstrou performance insatisfatória, com previsões que não se aproximam da demanda real. Isso indica que o modelo tem sérias limitações para lidar com a complexidade dos dados de demanda de encanamento.

TF(I-10-15-10-O) – (Figura 18, cap. 5)

Demonstrou desempenho satisfatório, capturando diversas oscilações e tendências presentes na demanda real. A demanda prevista pela RN está bastante alinhada com a real em muitos pontos, demonstrando uma boa capacidade até de seguir as variações.

TK(I-10-O) – (Figura 32, cap. 5)

Este modelo apresentou uma performance insatisfatória, com previsões que não se aproximam da demanda real, assim como seu par de mesmo número de camadas e neurônios, mas da biblioteca TensorFlow, todavia, obteve melhorias e o comportamento da curva se assemelhou mesmo com grande distanciamento em volume.

TK(I-10-15-10-O) – (Figura 42, cap. 5)

Mesmo com maior número de camadas e neurônios que o anterior este modelo possuiu uma performance insatisfatória, tendo resultados idênticos ao seu par de imaginada maior capacidade.

4.4 Análise da série temporal da Ferragem

TF(I-10-O) – (Figura 12, cap. 5)

Mesmo sendo um modelo simples obteve boa aproximação com a demanda real. Em alguns pontos, a curva prevista pelo modelo se alinha bem com a curva real, capturando de maneira eficaz as principais tendências e oscilações da demanda. Apesar de algumas discrepâncias em momentos de inversões de tendência, a rede neural apresenta uma performance sólida para predizer a demanda de ferragem.

TF(I-10-15-10-O) – (Figura 27, cap. 5)

O resultado obtido por esse modelo foi muito próximo do seu par com menos neurônios e camadas da mesma biblioteca, diferente de uma melhoria como imaginado.

TK(I-10-O) – (Figura 38, cap. 5)

Mesmo tendo previsões que não se aproximam da demanda real há um leve movimento ascendente na curva prevista, mostrando alguma tentativa de acompanhar a tendência geral, toda via seus resultados foram insatisfatórios.

TK(I-10-15-10-O) – (Figura 48, cap. 5)

O resultado obtido por esse modelo foi inferior ao seu par com menos neurônios e camadas da mesma biblioteca, diferente de uma melhoria como imaginado.

4.5 Análise da série temporal da Pintura

TF(I-10-O) – (Figura 15, cap. 5)

Esta RN exibiu uma performance insatisfatória, com previsões que não se aproximam da demanda real. Mesmo assim se mostrou mais eficiente que o mesmo modelo usado para a previsão de Concreto, pois teve uma leve mimetização da curva durante a fase de previsão.

TF(I-10-15-10-O) – (Figura 30, cap. 5)

A curva prevista pela rede neural está, em geral, bem alinhada com a curva real, refletindo adequadamente os picos e vales na demanda de pintura. Embora haja algumas pequenas discrepâncias.

TK(I-10-O) – (Figura 40, cap. 5)

Apesar de ter apresentado uma discrepância significativa no volume das previsões em relação à demanda real, conseguiu mimetizar bem a curva de tendência, acompanhando as principais oscilações da curva real, capturando adequadamente os padrões de subida e descida nos dados.

TK(I-10-15-10-O) – (Figura 50, cap. 5)

Mesmo com maior maior complexidade que o anterior este subestima ainda mais o volume da demanda real, e ainda por cima com menor capacidade de replicar comportamento das variações.

5 CONCLUSÕES GERAIS

Ao comparar as bibliotecas PyTorch e TensorFlow na previsão de demanda destes diversos materiais, observamos diferenças significativas tanto no desempenho quanto na capacidade de captar a complexidade dos dados. As redes neurais com apenas 10 neurônios internos (I-10-O) mostraram-se geralmente insuficientes para modelar a demanda real, independentemente da biblioteca utilizada. Em muitos casos, essas redes geraram previsões com grandes discrepâncias em relação ao volume real, não conseguindo capturar adequadamente as oscilações e tendências presentes nos dados. Este problema foi especialmente evidente nas previsões usando PyTorch, como

observado nos gráficos de encanamento e concreto, onde as previsões ficaram completamente discrepantes da demanda real.

Por outro lado, as redes neurais mais complexas, com a arquitetura I-10-15-10-O, apresentaram um desempenho notavelmente melhor. Essas redes conseguiram seguir mais de perto as tendências e oscilações da demanda real, especialmente quando implementadas com TensorFlow. Por exemplo, as previsões para cimento e ferragem usando TensorFlow com a arquitetura mais complexa foram bem alinhadas com a demanda real, capturando as variações de maneira eficaz. No entanto, mesmo com essa arquitetura mais avançada, PyTorch teve dificuldades, como visto nas previsões para concreto e encanamento, onde a subestimação persistiu apesar da melhoria em capturar a forma geral das curvas.

Em conclusão, tanto a escolha da biblioteca quanto a complexidade da rede neural influenciam significativamente a precisão das previsões de demanda. TensorFlow, junto com redes neurais mais complexas (I-10-15-10-O), tendem a fornecer resultados mais alinhados com a demanda real, capturando melhor o volume, as oscilações e as tendências. Redes neurais simples (I-10-O) e o uso de PyTorch necessitam possivelmente de maiores ajustes e treinamentos para alcançar a mesma precisão nas previsões.

Como já visto anteriormente, uma rede neural que analise dados como índices de preços de materiais de construção, tijolos, cimento, blocos de concreto e outros, tem diversas aplicações na indústria da construção civil e economia de modo geral. Elas podem ser utilizadas para prever os futuros valores dos materiais, auxiliando empresas a planejar compras, ajustar estratégias e tomar decisões informadas. Além disso, a análise de tendências e padrões nos dados históricos possibilita a identificação de variações sazonais, ciclos econômicos e mudanças de longo prazo, fornecendo insights valiosos para a tomada de decisões estratégicas, planejamento de estoque, projeções de investimento e estudos de viabilidade de projetos. Em resumo, redes neurais podem oferecer benefícios significativos ao setor, permitindo uma gestão mais eficiente, otimização de recursos e melhor planejamento econômico.

Com base no presente estudo, algumas perguntas ou discussões adicionais podem ser relevantes para futuros temas de pesquisa, como:

Como as previsões de preços de materiais de construção podem afetar a tomada de decisões estratégicas e o planejamento de projetos na indústria da construção? É

relevante discutir como as informações geradas pela rede neural podem ser aplicadas em diferentes contextos, como a gestão de estoques, a seleção de fornecedores, a precificação de projetos e a identificação de oportunidades de investimento.

Quais são os desafios e limitações associados ao uso de redes neurais para previsão de preços de materiais de construção? Seria interessante analisar as restrições e obstáculos potenciais, como a disponibilidade de dados, a sensibilidade a mudanças no mercado, a necessidade de atualização contínua do modelo e a interpretabilidade dos resultados, a fim de fornecer uma visão abrangente sobre as capacidades e as limitações desse tipo de abordagem.

Quais são as possíveis melhorias ou extensões que podem ser feitas nesse estudo? Considerando as descobertas e resultados obtidos, seria válido explorar a aplicação de diferentes técnicas de modelagem, como redes neurais recorrentes (RNNs) ou modelos de aprendizado de máquina mais avançados, bem como incorporar dados de séries temporais de outras fontes relevantes. Isso pode ajudar a melhorar a precisão das previsões e a robustez do modelo.

REFERÊNCIAS BIBLIOGRÁFICAS

MACHLINE, C. Cinco décadas de logística empresarial e administração da cadeia de suprimentos no Brasil. **RAE**, São Paulo, v. 51, n.3, maio/jun. 2011, p227-231.

Aragão, Andréa Barcellos. **Modelo para SCM baseado em integração de processos, compartilhamento de informação e medidas de desempenho**. Rio de Janeiro, 2004. 110p. Dissertação de Mestrado - Departamento de Engenharia Industrial, Pontifícia Universidade Católica do Rio de Janeiro.

GOMES, et al. Pressupostos da gestão da cadeia de Suprimentos: evidências de estudos sobre a Indústria automobilística. **GESTÃO & PRODUÇÃO**, v.11, n.3, set.-dez. 2004, p.275-288.

FERREIRA, A.E.T. - **Estimação do ângulo de direção por Vídeo para Veículos Autônomos** utilizando Redes Neurais Convolucionais Multicanais - Universidade de Brasília - Brasília - 2017;

HEGLER, J. A.; LÄTZER, J.; SHEHU, A.; CLEMENTI, C.; WOLYNES, P. G., **Restriction versus guidance in protein structure prediction**, Proceedings of the National Academy of Sciences, vol. 106–36, 2009, pp. 15302–15307.

BAILY, Peter - **Compras Princípios e Administração** – São Paulo: Atlas, 2000.

BANCO NACIONAL DO DESENVOLVIMENTO. Seminário ‘**Novo Ciclo de Investimentos em Infraestrutura e a Transparência na Construção Civil**’. Rio de Janeiro: BNDES, 2019. Disponível em: https://cbic.org.br/wp-content/uploads/2019/09/Seminario_BNDES_CBIC_25.04.2019.pdf ;

BOWERSOX, Donald J. et al. - **Gestão logística da cadeia de suprimentos** -[recurso eletrônico] /; revisão técnica: Alexandre Pignanelli ; tradução: Luiz Claudio de Queiroz Faria. – 4. ed. – Dados eletrônicos. – Porto Alegre: AMGH, 2014;

BRISCOE, Geoffrey; DAINTY, Dainty - **Construction supply chain integration: an elusive goal?** -Vol. 10 No. 4. Reino Unido, 2005;

CARVALHO, Jonatas Sena - **Avaliação do desempenho de fornecedores da cadeia de suprimentos na construção civil** - XXXV encontro nacional de engenharia de produção - Fortaleza, CE, Brasil, 13 a 16 de outubro de 2015. Disponível em: http://www.abepro.org.br/biblioteca/TN_STO_206_222_26882.pdf ;

CAVINATO, Joseph L.; KAUFFMAN, Ralph. G. - **The purchasing handbook** – New York: McGraw-Hill, 2000;

CHAGAS, Davi das Neves; OLIVEIRA, Ricardo Augusto Rabelo - **Introdução às redes neurais densas** - Universidade Federal de Ouro Preto – Ouro Preto – 2021;

MANNING.C.D., **Computational Linguistics and Deep Learning Computational Linguistics**, 41(4),p701–707. 2015;

ROSENBLATT. F., **The perceptron, a perceiving and recognizing automaton Project**. Cornell Aeronautical Laboratory, 1957;

CUNHA, A.M. et al. – **Construção Civil** – Versão Impressa Porto Alegre: SAGAH, 2017;

Data Science Academy. **Deep Learning Book**, 2021. Disponível em: <<https://www.deeplearningbook.com.br/>>. Acesso em: 10 jun. de 2021;

FRANTZ, A.C.R. - **Compras empresariais: um estudo de caso no grupo diários associados** - Brasília/DF, 2010; Disponível em:

<https://repositorio.uniceub.br/jspui/bitstream/235/10044/1/20550817.pdf> ;

HAGA, H. C. R. - **Gestão da rede de suprimentos na construção civil: integração de um sistema de administração da produção** - Dissertação de Mestrado apresentada a Universidade de São Paulo, São Carlos, 2000;

Halpin, Daniel W. - **Administração da construção civil** - tradução Orlando Celso Longo, Vicente Custódio Moreira de Souza. - 2. ed. - [Reimpr.]. - Rio de Janeiro: LTC, 2017;

KRAINER, C.W.M. - **Gestão das relações interorganizacionais na cadeia de suprimentos convencional da construção civil: uma revisão sistemática** - XXXIX encontro nacional de engenharia de produção - Santos, São Paulo, Brasil, 15 a 18 de outubro de 2019. Disponível em: http://www.abepro.org.br/biblioteca/TN_STO_291_1640_38624.pdf ;

MAGALHAES, E. - **Gestão da cadeia de suprimentos** - Editora FGV, 2015;

NAGY, T.K. - **Aplicação de redes neurais em redes de suprimento: uma revisão bibliográfica** - XXXVIII encontro nacional de engenharia de produção - Maceió, Alagoas, Brasil, 16 a 19 de outubro de 2018;

PAOLESCHI, Bruno - **Cadeia de suprimentos** - 1. ed. - São Paulo: Érica, 2014;

SPURI, A.G. - **Supply chain management: uma revisão bibliométrica** - XXXIX encontro nacional de engenharia de produção - Santos, São Paulo, Brasil, 15 a 18 de outubro de 2019. Disponível em:

http://www.abepro.org.br/biblioteca/TN_STO_000_1640_38196.pdf ;

TISAKA, Maçahico - **ORÇAMENTO NA CONSTRUÇÃO CIVIL – consultoria, projeto e execução** – 1ª edição, São Paulo: Editora Pini, 2006.

LISTA DE IMAGENS GERADAS PELOS MODELOS

- Rede I-10-O com TensorFlow: ENCANAMENTO




Figura 5.1

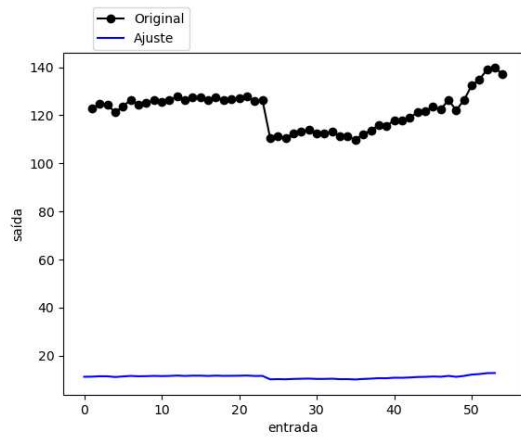


Figura 5.2

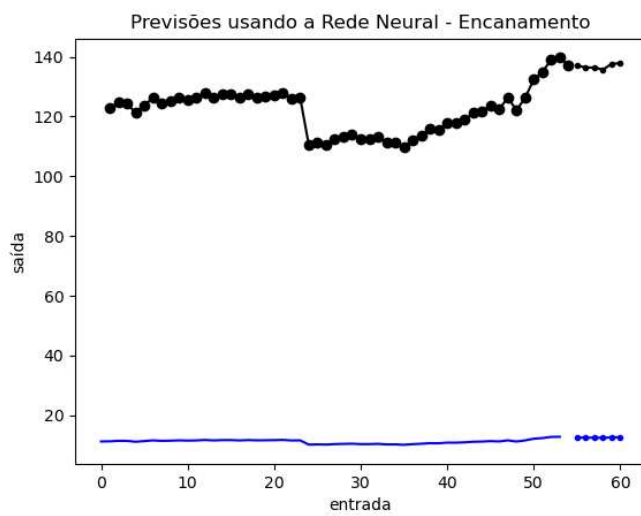


Figura 5.3

- Rede I-10-O com TensorFlow: CIMENTO

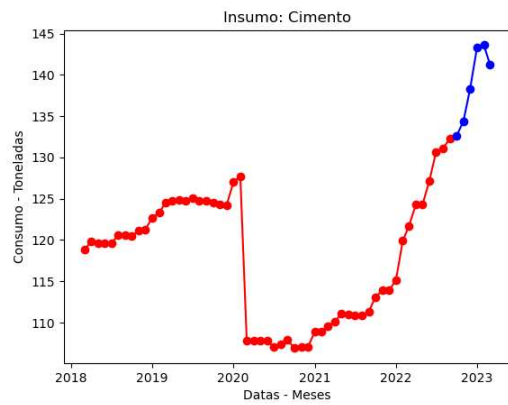


Figura 5.4




Figura 5.5

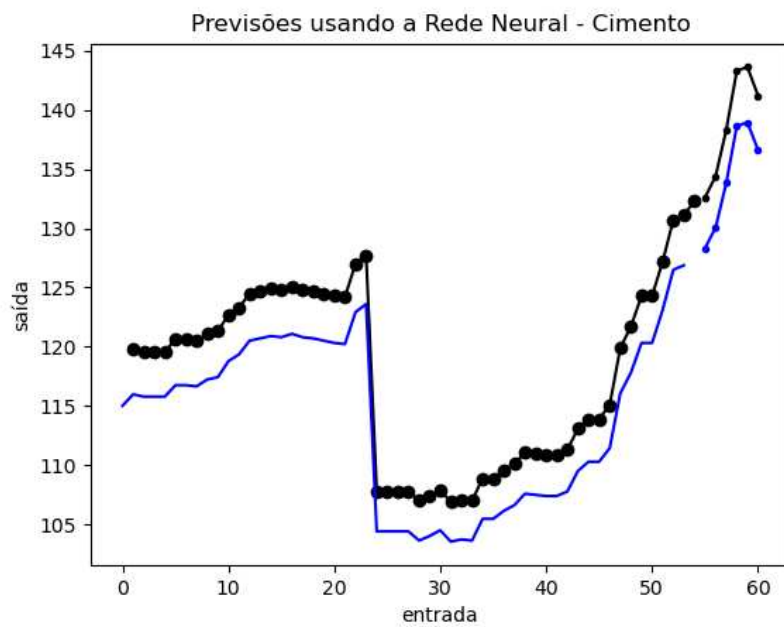


Figura 5.6

- Rede I-10-O com TensorFlow: CONCRETO

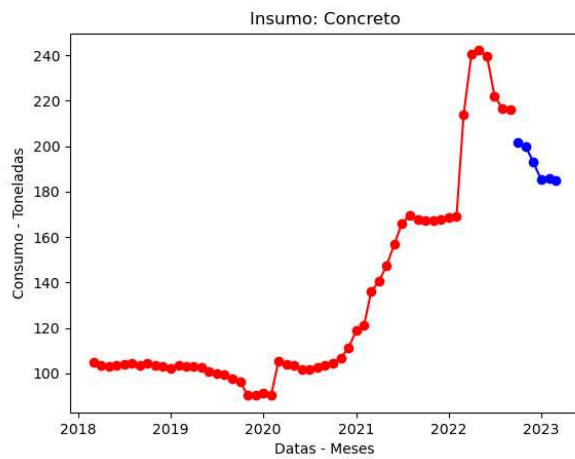


Figura 5.7




Figura 5.8

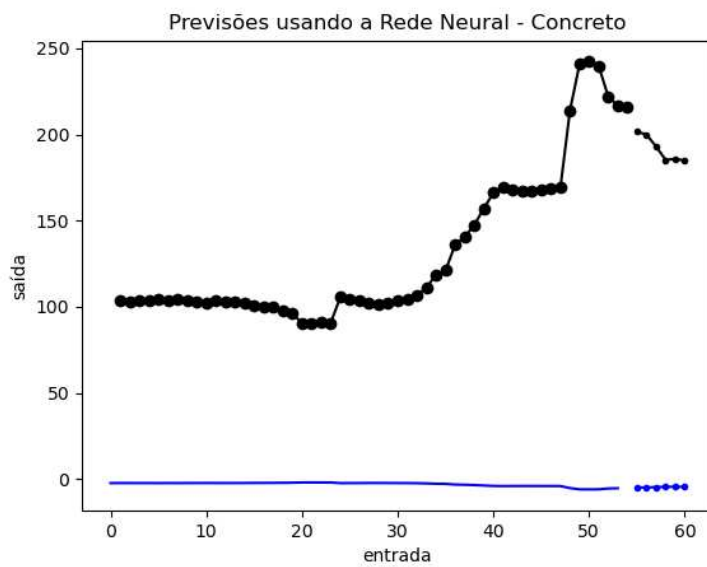


Figura 5.9

- Rede I-10-O com TensorFlow: FERRAGEM




Figura 5.10




Figura 5.11

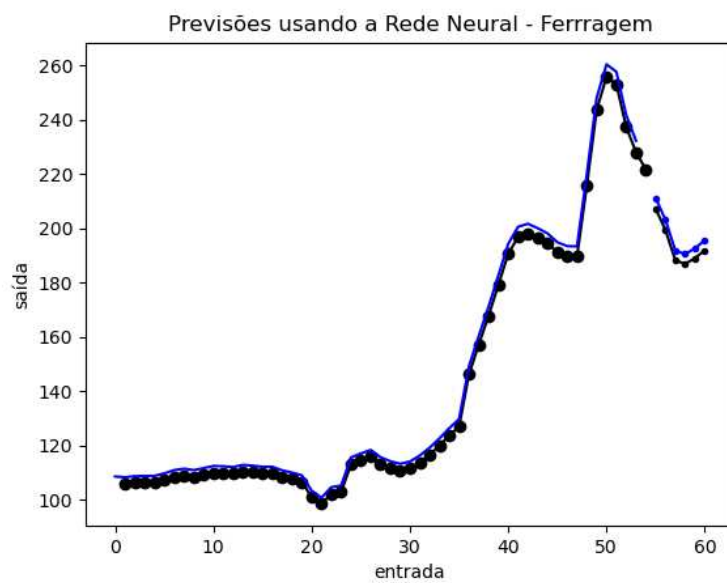


Figura 5.12

- Rede I-10-O com TensorFlow: PINTURA

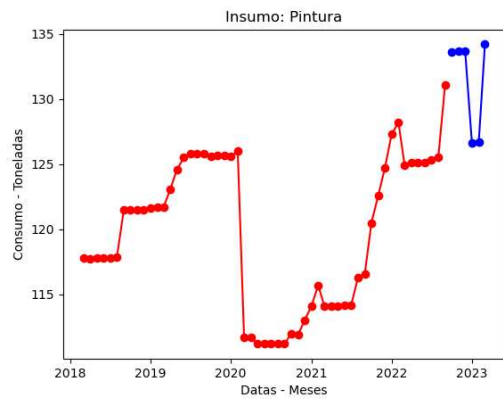


Figura 5.13




Figura 5.14




Figura 5.15

- Rede I-10-15-10-O com TensorFlow: CANOS

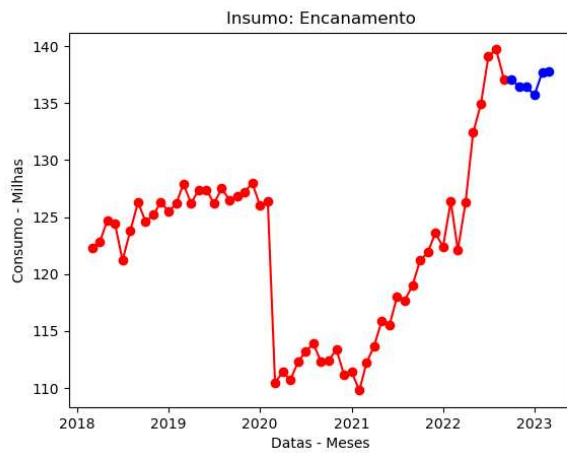


Figura 5.16




Figura 5.17

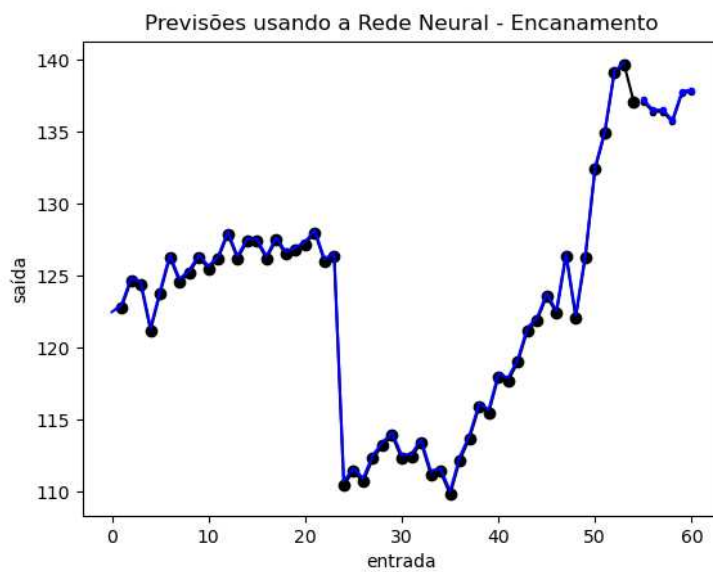


Figura 5.18

- Rede I-10-15-10-O com TensorFlow: CIMENTO




Figura 5.19




Figura 5.20




Figura 5.21

- Rede I-10-15-10-O com TensorFlow: CONCRETO

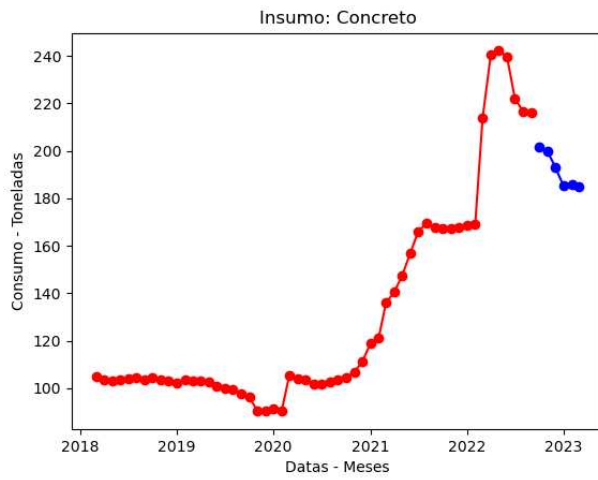


Figura 5.22




Figura 5.23

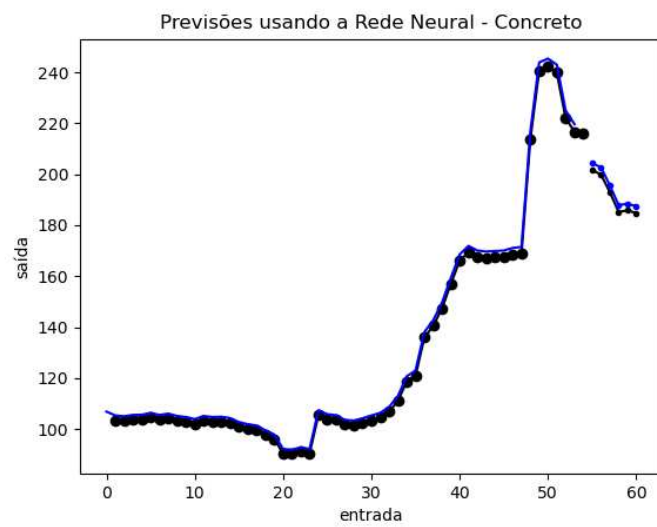


Figura 5.24

- Rede I-10-15-10-O com TensorFlow: FERRAGEM




Figura 5.25




Figura 5.26




Figura 5.27

- Rede I-10-15-10-O com TensorFlow: PINTURA

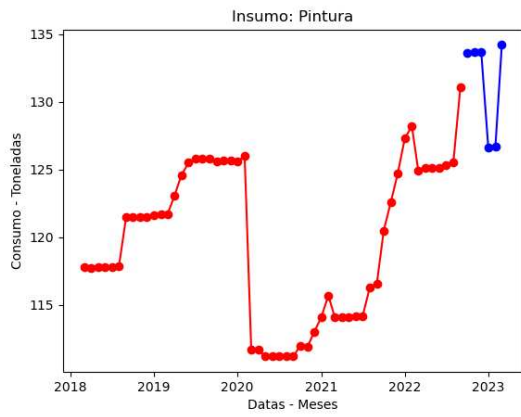


Figura 5.28




Figura 5.29




Figura 5.30

- Rede I-10-O com PyTorch: CANOS




Figura 5.31




Figura 5.32

- Rede I-10-O com PyTorch: CIMENTO




Figura 5.33




Figura 5.34

- Rede I-10-O com PyTorch: CONCRETO




Figura 5.35




Figura 5.36

- Rede I-10-O com PyTorch: FERRAGEM




Figura 5.37




Figura 5.38

- Rede I-10-O com PyTorch: PINTURA




Figura 5.39




Figura 5.40

- Rede I-10-15-10-O com PyTorch: CANOS




Figura 5.41




Figura 5.42

- Rede I-10-15-10-O com PyTorch: CIMENTO




Figura 5.43




Figura 5.44

- Rede I-10-15-10-O com PyTorch: CONCRETO




Figura 5.45




Figura 5.46

- Rede I-10-15-10-O com PyTorch: FERRAGEM




Figura 5.47




Figura 5.48

- Rede I-10-15-10-O com PyTorch: PINTURA




Figura 5.49




Figura 5.50