



GABRIEL ARCURI MARTINS

**PREVISÃO DO PREÇO FUTURO DO CRÉDITO DE
CARBONO NO MERCADO EUROPEU UTILIZANDO
MÉTODOS DE REGRESSÃO LINEAR ARIMA PROPHET E
RANDOM FOREST**

**LAVRAS – MG
2023**

GABRIEL ARCURI MARTINS

**PREVISÃO DO PREÇO DO CRÉDITO DE CARBONO NO MERCADO EUROPEU
UTILIZANDO MÉTODOS DE REGRESSÃO LINEAR
ARIMA PROPHET E RANDOM FOREST**

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia Florestal, para obtenção do título de Bacharel.

Prof. Dr. Lucas Rezende Gomide
Orientador
Ms. Evandro Nunes Miranda
Coorientador

**LAVRAS – MG
2023**

AGRADECIMENTOS

Acredito que nada disso seria possível sem aqueles que vieram antes de mim e construíram o que a UFLA é hoje, por eles sou grato.

Dedico esse trabalho aos meus pais Inácio e Elisa que sempre me apoiaram e incentivaram, sem eles não seria ninguém. Dedico também aos meus colegas de curso e todos que fizeram parte dessa trajetória e me incentivaram de alguma maneira.

Agradeço aos professores da UFLA, principalmente aos do Departamental Florestal, que sempre fazem o possível para ajudar aqueles que os procuram e sempre se esforçam ao máximo para que nós consigamos aprender e evoluir.

Agradeço também principalmente ao meu orientador, Lucas Rezende Gomide que, apesar das circunstâncias, sempre procurou me motivar a seguir em frente.

Aos membros da banca examinadora pelo seu tempo.

À Universidade Federal de Lavras, e ao Departamento de Ciências Florestais que tornou possível a realização da minha graduação.

Obrigado!

RESUMO

Considerando a importância das transformações necessárias nos hábitos humanos para que os impactos do efeito estufa sejam reduzidos e o planeta continue habitável, os créditos de carbono vêm se tornando uma forma efetiva de contabilizarmos, responsabilizar e conseguirmos compensar pelo aquilo que é emitido. Esse estudo procura entender melhor o mercado dessa commodity e tem a intenção comparar as séries de modelagem, ARIMA, *Prophet* e *Random Forest*, através da utilização do software R Core, com os dados de preço disponibilizados pelo Internacional Carbon Action Partnership, para prever o preço futuro dessa ação e com isso otimizar a tomada de decisões daqueles que desejam comprar, vender ou possuem desse bem. Através da análise foram comparados os erros dos métodos e conseguimos observar que o *Prophet* obteve as melhores métricas e conseguiu variar junto de uma variação real.

Palavras chaves: Crédito de Carbono. Modelagem. *Random Forest*. Séries Temporais. *Prophet*. ARIMA. Previsão.

ABSTRACT

Considering the actual need and importance of a change in the human behavior to slow down the greenhouse effects so the planet can keep habitable for the all human race, the carbon credits have become an important way to measure the total releases of greenhouse gasses, charge and get a way to make up for their releases. This work tries to understand and compare some modeling series, ARIMA, *Prophet* e *Random Forest*, through the use of the software R Core, with the data available by the International Carbon Action Partnership with the goal of forecasting the price of the action and the time people decide to sell or buy it. Through the analysis, the errors of the methods were compared and we were able to observe that the *Prophet* obtained the best metrics and could predict a real variation with the price.

Key-words: Carbon Credit. Modeling. Random Forest. Time Series. Prophet. ARIMA. Forecast.

LISTA DE FIGURAS

Figura 1 - Emissões de CO₂ por fontes de energia por combustão e processos industriais.	
13	
Figura 2 - Variação anual de emissões de CO₂ por fontes de energia a combustão e processos industriais.....	16
Figura 3 - Precificação do crédito de carbono EU-ETS.....	14
Figura 4 - Fluxograma 1 : Fluxograma da metodologia ARIMA.....	20
Figura 5 - Resultado dos algoritmos aplicados.....	24

LISTA DE TABELAS

Tabela 1 - Critérios de seleção dos modelos no processo de validação.....23

Tabela 2 - Métricas de avaliação dos modelos testados.....24

SUMÁRIO

1.	INTRODUÇÃO	8
2.	REVISÃO DE LITERATURA.....	10
2.1.	Estoques e emissão de carbono.....	10
2.2.	Mercado de carbono	13
2.3.	Legislação e mercado brasileiro	15
2.4.	Séries temporais	17
3.	MATERIAL E MÉTODOS	18
3.1.	Base de dados	18
3.2.	Previsão do preço do crédito de carbono	18
3.3.	ARIMA	19
3.4.	Prophet	19
3.5.	Random forest	20
3.6.	Métricas de avaliação	20
4.	RESULTADOS	22
5.	DISCUSSÃO	23
6.	CONCLUSÃO	25
	REFERÊNCIAS	26
	ANEXO 1 - Código utilizado para a modelagem de previsão.....	29

1. INTRODUÇÃO

O aumento dos impactos consequentes da poluição humana forçou diversos países de todo o mundo a se juntarem, com a finalidade de encontrar, em conjunto, soluções através de acordos possíveis de serem realizados para que esses impactos sejam reduzidos e o planeta continue sendo habitável para as próximas gerações.

Assim, em 1972, foi realizada a primeira conferência internacional relacionada ao tema, ela ocorreu em Estocolmo, capital da Suécia teve como título, Conferência das Nações Unidas Sobre o Desenvolvimento e Meio Ambiente Humano. Durante essa conferência diversos assuntos foram abordados, como qualidade da água, ar e solo com o objetivo de descrever as responsabilidades e direcionar na criação de novas políticas de meio ambiente. No total 113 países participaram, e no final chegaram à conclusão que todos deveriam diminuir ou manter a suas fontes de poluição no nível da época, para que com isso o aquecimento global fosse freado. Mas para que isso ocorresse, diversos países deveriam abrir mão de crescer economicamente, o que não era viável para eles (GURSKI, 2012).

Essa primeira conferência deu início a uma série de outras, que abriram um leque de novas discussões voltadas para o clima e o meio ambiente.

Em 1988, foi criado, pela Organização Meteorológica Mundial em conjunto com a United Nations Environment Programme (UNEP), o Painel Intergovernamental sobre Mudança Climática (IPCC); Esse mecanismo procura produzir relatórios com a intenção de alertar a população mundial sobre os perigos do aquecimento global, visando a criação de mecanismos mitigadores para diminuição desses efeitos (WOLFFBÜTTEL, 2007)

Em 1995, no intervalo de 28 de março a sete de abril, em Berlim, com a participação de 117 partes, foi realizada a primeira Conferência das Partes (COP). Essa conferência é realizada anualmente até hoje. Nessa primeira conferência, foi discutida principalmente a responsabilidade dos países desenvolvidos nas altas emissões de gases do efeito estufa (GEE) em comparação aos países em desenvolvimento (MCGIVERN, 1998).

Em 1997 houve a COP3, realizada em Quioto, Japão, com a participação de 159 nações, foi o primeiro tratado a definir uma meta de controle dos gases do efeito estufa, colocando como objetivo uma redução nos níveis de carbono em 5% dos níveis de 1990. Essa meta foi definida para ser alcançada entre os anos de 2008 e 2012. Nesse texto, o ato de vendas de emissões foi denominado “hot air” (SENADO FEDERAL, 2004).

Em 2005, foi lançado o primeiro mercado regulamentado internacional de crédito de carbono, o “Union European Emissions Trading System” (EU-ETS, ou sistema de trocas de emissões da União Europeia, em uma livre tradução.)

Em 2015, ocorreu em Paris, França, a COP 21, com a participação de 195 países e a União Européia, nessa conferência foi assinado o acordo de Paris. Esse acordo tem como objetivo frear o aumento da temperatura média da terra em no máximo 2°C. Para realização desse objetivo o acordo prevê a possibilidade de cooperação entre os países por meio de instrumentos de mercado. Hoje, o principal deles é a venda dos créditos de carbono de países e empresas com números menores que a meta estabelecida, podem repassar essa diferença em créditos a outro que não tenha cumprido com as metas (MINISTÉRIO DA CIÊNCIA TECNOLOGIA E INOVAÇÃO, 2021).

Com o aumento da demanda para um obtermos um mundo mais sustentável, o mercado procura se adaptar para poder se encaixar nesse movimento, com projetos que diminuem ou retiram GEE da atmosfera. Como nem todos conseguem cumprir com os limites estabelecidos, e querem estar presentes no movimento de um mundo sustentável, estas veem na compra de crédito de carbono uma maneira de compensar por suas emissões. Com novas empresas e países tentando atingir suas metas de emissões, o valor do crédito tende a se valorizar pois existe uma maior demanda , conforme tentamos atingir a meta de carbono 0.

Para facilitar a compensação é importante um mercado seguro de vendas de créditos de carbono, em que a informação dos créditos seja confiável nos critérios de medição dos créditos. Hoje, no planejamento das empresas, também é necessário levar em consideração as emissões geradas e as formas de compensá-las, com isso o mercado de carbono tende a ser muito promissor já que muitas empresas estão aderindo a essa filosofia. Para estas é importante ter o conhecimento de como o valor do crédito flutua, já que esta irá trabalhar com ela.

Para venda de crédito de carbono é importante estimar e prever o carbono estocado para sua comercialização. Para um planejamento assertivo usam-se modelos de previsão para compreender e estimar o comportamento do valor do crédito no futuro. Assim, modelos como o "ARIMA", "*Prophet*" e "*Random Forest*", são utilizados para mitigar as incertezas de eventos futuros, facilitando no momento de tomada de decisão.

Pensando nisso, utilizou-se esses modelos para a previsão do valor do crédito do mercado de carbono no mercado EU-ETS. E com isso avaliar a melhor escolha para tomada de decisão por meio dos gestores do mercado.

2. REVISÃO DE LITERATURA

2.1. Estoques e emissão de carbono

De acordo com o *World Resources Institute* (WRI), durante o intervalo de 2001 e 2021 conseguimos quantificar que as emissões de CO₂ por parte das florestas era menor do que a quantidade absorvida, ou seja, tivemos um déficit positivo sobre o carbono emitido pelas florestas. As emissões de carbono por conta de incêndios e desmatamento são responsáveis pela liberação de cerca de 8,4 Gt CO₂/ano, enquanto as florestas capturam uma média de 15,5 Gt CO₂/ano, com isso podemos concluir que as florestas possuem em média um déficit positivo de 7,2 gigatons de carbono capturado por ano (MITCHIE, 2022).

É calculado que as florestas mundiais tem em sua composição cerca de 861 gigatoneladas (Gt) de carbono. Desses 861 Gt 44% está no solo a até um metro de profundidade, 42% está em biomassa viva, estando acima ou abaixo do solo, 8% em madeira morta, e 5% em serapilheira. Todo esse carbono é equivalente à emissão de um século de emissões, mantendo-se os níveis atuais, que estão na casa de Gt (PAN, 2011).

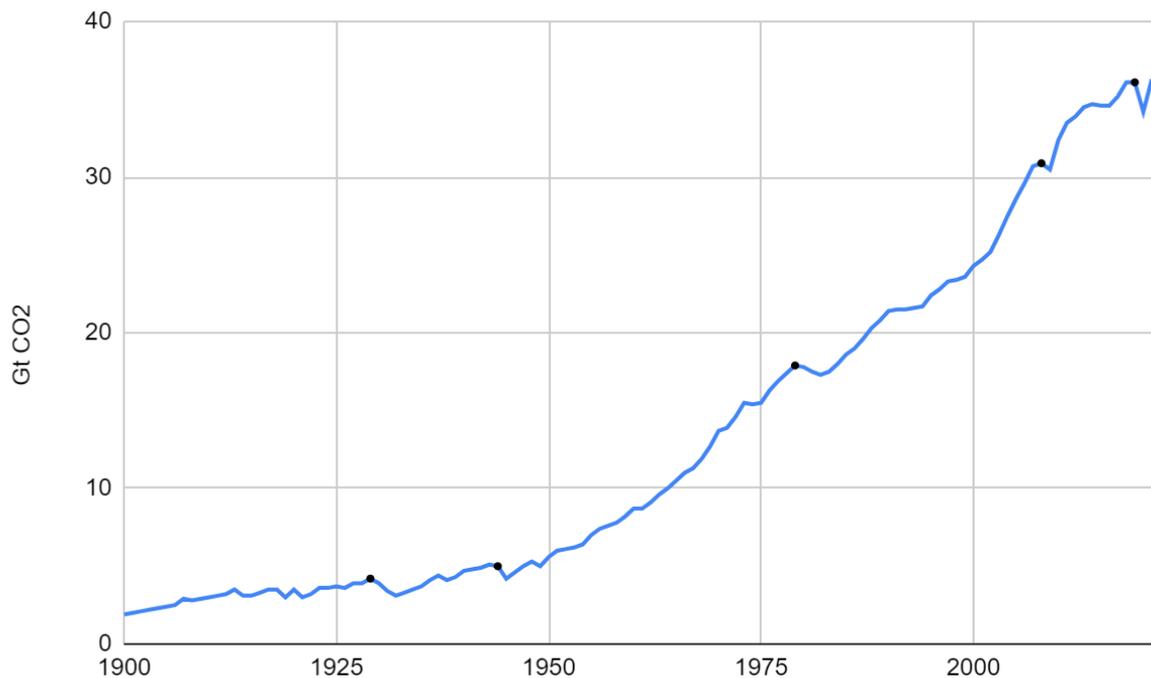
As emissões e capturas por parte da floresta variam de acordo com o tipo de bioma em que ela se encontra, florestas tropicais são as que mais emitem CO₂ mas também são as que mais capturam, a diferença entre as emissões e capturas ficam em torno de 1,5 Gt capturado por ano. A floresta temperada tem a segunda maior taxa de captura e suas emissões são pequenas quando comparados a florestas tropicais, sendo assim essa floresta possui um déficit positivo muito maior que a floresta tropical com cerca de 3,5 Gt CO₂ capturado por ano. Mas não pode-se esquecer das principais fontes de emissão de GEE, de acordo com a *Environment Protection Agency* (EPA), a eletricidade e produção de calor são responsáveis por 25% dos GEE emitidos na atmosfera, a agricultura junto com as florestas e outros usos de solo são responsáveis por 24% das emissões, a indústria por 21%, transportes 14%, construções 6%, e outras formas de energia 10% (IPCC 2014).

De acordo com o *International Energy Agency* (IEA), o ano de 2020 foi um ano atípico no que se refere a emissão de CO₂ na atmosfera, foi um dos poucos anos em que houve redução na quantidade emitida para atmosfera em relação ao ano anterior. Em 2019 tivemos um total lançado na atmosfera de 36,1 Gt CO₂, já em 2020 tivemos um total de 34,2 Gt CO₂, lançados para atmosfera, uma diferença de quase dois Gt. Em 2021 já houve um aumento possuindo uma quantidade emitida maior que todos os anos anteriores, sendo liberados 36,3 Gt CO₂ (IEA, 2022).

Essa atipicidade é explicada pela pandemia do COVID-19 (LE QUÉRÉ, 2021). Os momentos em que passamos por crises de nível mundial são os momentos em que conseguimos observar déficits de emissão de carbono, já que o poder de consumo mundial decaiu e, junto disso a queda na demanda de energia e com isso no consumo dos combustíveis fósseis (IEA, 2022). Alguns destaques vão para os anos de 1929, em que houve redução da emissão por três anos seguidos, durante alguns anos da Segunda Guerra Mundial, também podemos observar que ocorreu uma queda nas emissões. 1979, ano em que se deu início a crise do petróleo e 2008 com a crise financeira.

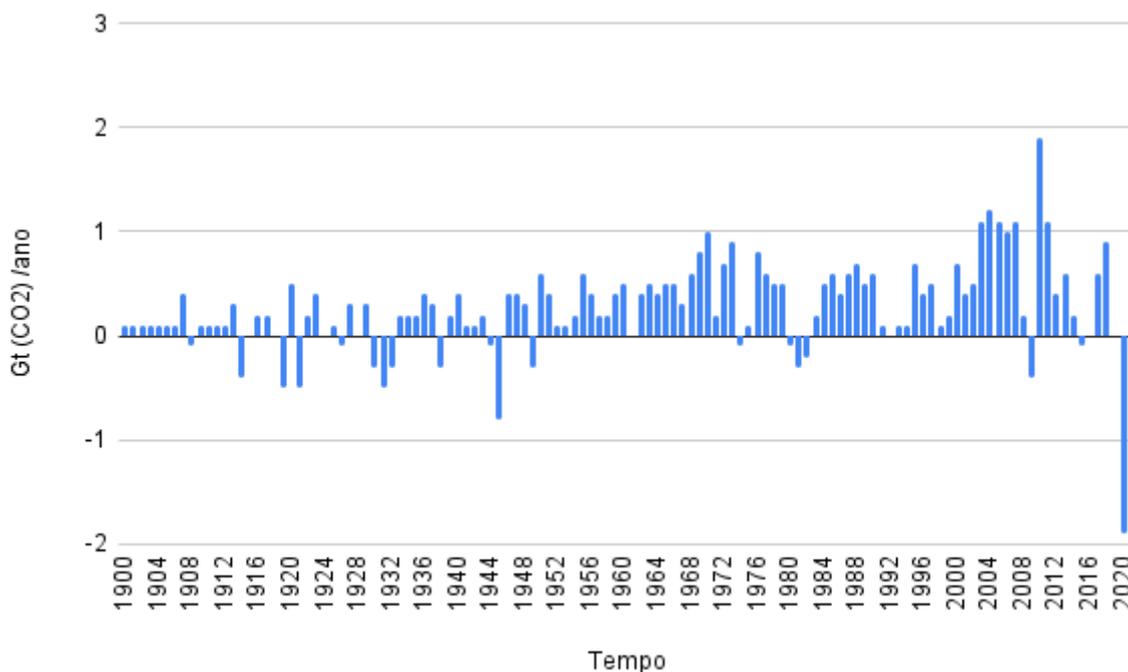
Com os dados emitidos pela IEA observa-se a quantidade emitida de CO₂ durante os anos. Esses dados demonstram claramente o aumento exponencial das emissões. Abaixo temos o gráfico com os dados das emissões globais de CO₂, dados históricos que começam no ano de 1900 e vão até o ano de 2021 (Figura 1). Em seguida um gráfico demonstrando a diferença na quantidade de emissões em anos seguintes (Figura 2).

Figura 1: Emissões de CO₂ por fontes de energia por combustão e processos industriais.



Fonte: IEA (2021).

Figura 2: Variação anual de emissões de CO₂ por fontes de energia a combustão e processos industriais.



Fonte: IEA (2021).

Hoje, o maior emissor de gás carbônico no mundo é a China. Em 2021 ela foi responsável por lançar na atmosfera 11,9 Gt de CO₂, em seguida vieram os EUA com 4,6 Gt CO₂. Seguidos pela Índia e União Européia, ambos muito próximos nas emissões atuais, a Índia com cerca de 2,5 Gt de CO₂ e a UE com 2,7 Gt de CO₂. A UE e os EUA apresentam maior tendência de queda de emissões nos últimos anos, enquanto China e Índia vêm crescendo (CRIPPA, 2021).

O crédito de carbono vem apresentando já a alguns anos em constante expansão no mercado financeiro. A necessidade de termos um mundo sustentável vem aumentando a cada ano, os acordos internacionais com objetivo de recuperação da atmosfera e frear o aumento de temperatura vem sendo cada vez mais extremos. Uma das formas que encontramos para mitigar os efeitos danosos das emissões causadas, é a de compensação das emissões dos gases de efeito estufa, principalmente o dióxido de carbono (CO₂), o metano (CH₄), e o óxido nitroso (N₂O). Com esta prática, uma série de tratados e leis foram implementadas no mundo para incentivar e facilitar a comercialização do crédito de carbono.

2.2. Mercado de carbono

O mercado de carbono é baseado na ideia de que todos possuem limites de emissão. Com este limite definido, determina-se se o emissor receberá ou deverá créditos de carbono, baseado na quantidade limite e suas emissões em um determinado período de tempo. Aqueles que conseguirem estar abaixo do limite, terão o direito de vender esse excedente para aqueles que ultrapassaram (REIS, 2008).

Hoje, existem no mundo mais de 30 mercados regulamentados de carbono, cada mercado tem suas características, um público alvo, e regras para medição do volume de carbono, venda e compra dos créditos, objetivos de redução, entre outros. Essas regras devem ser bem definidas e rígidas, difíceis de passar por alguma mudança, sempre seguindo critérios técnicos adequados para que a chance de um erro de medição seja minimizada. Mercados que não possuem regras bem definidas não passam confiança (EU-ETS, 2013).

O mercado com maior sucesso em todo mundo é o europeu “*EU Emissions Trading System*” (EU-ETS). De acordo com a *European Commission* (EC), a ideia dele veio ainda nos anos 2000 uma comissão de países europeus apresentaram uma série de ideias de como esse mercado poderia funcionar, essas ideias foram fortemente discutidas e moldaram o que futuramente viria a ser o mercado. Em 2003 as diretrizes do EU-ETS foram adotadas, e em 2005 o sistema foi lançado.

Esse mercado foi lançado e dividido em fases, a primeira planejada para começar em 2005 e terminar em 2007, a segunda de 2008 até 2012, e a terceira de 2013 a 2020. Cada qual com seus planos e objetivos. A primeira fase teve como lema “*learning by doing*”, numa livre tradução, “aprendendo fazendo”, isso se justifica por ser algo pioneiro que precisava sair do papel o quanto antes.

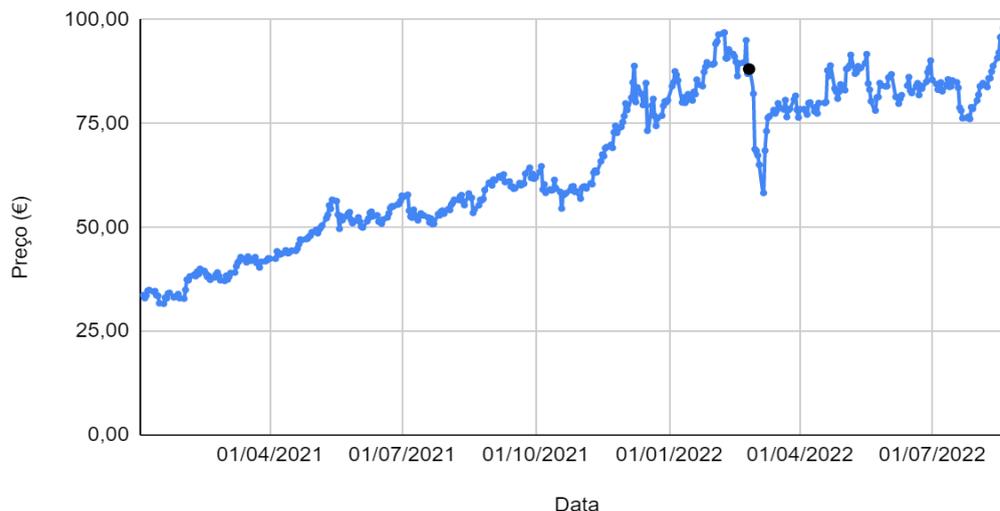
Algumas das características chaves para o sucesso da primeira fase foram, descobrir com clareza a grandeza das emissões de CO₂ por parte de geradores de energia e da indústria. Para aqueles que não cumprissem o limite pré-estabelecido seria aplicada uma multa de 40€ por tonelada de CO₂ ultrapassada. Outros pontos chave para o sucesso dessa primeira fase, foi em estabelecer o preço do crédito, zerar qualquer tipo de taxa na venda e compra entre os países Europeus, e em definir um ótimo sistema de monitoramento e verificação das emissões e medição do crédito. Como antes dessa fase, não se sabia com clareza a quantidade emitida pelos empreendimentos, os limites para esses foram estabelecidos por estimativa. Em 2007 foram emitidos tantos certificados de créditos de carbono e a procura foi tão baixa que o valor do crédito caiu a 0.

A segunda fase ocorreu no mesmo período definido pelo Protocolo de Quioto. O objetivo era que as médias de carbono na atmosfera fossem 5% menores que as de 1990. Nesse período a UE ainda necessitava atingir uma meta de redução muito grande de emissões para cumprir esse objetivo. Três novos países entraram no grupo desse mercado, foram eles, Islândia, Noruega e Liechtenstein. As emissões por óxido nitroso começaram a ser medida em diversos países, muitos leilões foram feitos por diversos países, a multa para quem não cumprisse com a meta passou para 100 € por tonelada. Também houve liberação para que empresas possam comprar desse mercado, essa medida fez com que 1,4 toneladas de CO₂ equivalente fosse comprado em curto período de tempo. O setor de aviação foi incluído nesse mercado a partir de 2012, mas apenas o setor de viagens exclusivamente europeias.

A fase 3, teve início em 2013, essa fase foi responsável por uma maior reestruturação no sistema quando comparado com as fases anteriores. Entre essas grandes mudanças, foi estabelecido um limite de emissões para toda União Europeia, ao invés de limites para cada país. Agora o padrão de vendas seria feito através de leilões, novos setores de emissão de gases de efeito estufa incluídos na compensação. Desde este ano, a venda de créditos por leilão se tornou o método padrão para a transferência de créditos de carbono (EU-ETS, 2013).

A variação de preço desse mercado vem tendo uma tendência de crescimento, em cinco anos o valor de cada crédito nesse mercado valorizou em mais de 10 vezes, com grandes variações em períodos de crise e incerteza. A variação mais recente e de maior valor, ocorreu a pouco tempo com o início da Guerra da Ucrânia. No dia oito de fevereiro de 2022 o crédito bateu seu valor recorde, atingindo o valor de 96,93 €, no dia 24 de fevereiro a Rússia invadiu a Ucrânia, um dia antes o valor de cada crédito estava em 95,07 €, nesse intervalo de um dia tivemos uma desvalorização do crédito em 8,46%. Essa queda exorbitante ocorreu até a data de sete de março de 2022, nesse dia o preço chegou a 58,3 €. Mesmo com essa crise no preço, o valor se recuperou rapidamente, atingindo 76,41 € em 10 de março de 2022. Abaixo temos o gráfico da precificação do crédito de carbono do mercado estudado, o gráfico tem início em quatro de janeiro de 2021, e vai até 10/02/2023. O ponto em destaque no gráfico foi o dia em que a Rússia declarou guerra com a Ucrânia e iniciou uma enorme queda no valor do preço do crédito no mercado EU-ETS.

Figura 3: Precificação do crédito de carbono EU-ETS.



Fonte: International Carbon Partnership.(2023)

2.3. Legislação e mercado brasileiro

O mercado brasileiro de crédito de carbono ainda é recente. Para ser regularizado internacionalmente necessita de normas e regulamentações que possibilitem sua implementação no país, para que com isso possamos ter metas e maior facilidade no comércio desses créditos. Para que com isso possamos atingir as metas dos acordos assinados pelo Brasil no COP.

No dia 19 de maio de 2022 foi editado o primeiro decreto que procura regulamentar o mercado de crédito de carbono no Brasil, o Decreto 11.075 de 19 de maio de 2022. Este decreto conta com 4 capítulos e 15 artigos que “estabelece os procedimentos para a elaboração dos Planos Setoriais de Mitigação das Mudanças Climáticas (PMMC), institui o Sistema Nacional de Redução de Emissões de Gases de Efeito Estufa (Sinare) e altera o Decreto nº 11.003, de 21 de março de 2022.”

O primeiro capítulo é intitulado como “DISPOSIÇÕES PRELIMINARES”. Esse capítulo é responsável pela definição de alguns termos como, crédito de carbono, crédito de metano, crédito certificado de redução de emissões, compensação de emissões de gases de efeito estufa, Contribuições Nacionalmente Determinadas (NDC), agentes setoriais, mensuração, relato e verificação, meta de emissão de gases de efeito estufa, mitigação, padrão de certificação do Sinare, unidade de estoque de carbono, e Planos Setoriais de Mitigação das Mudanças Climáticas.

O segundo capítulo é intitulado “DOS PLANOS SETORIAIS DE MITIGAÇÃO DAS MUDANÇAS CLIMÁTICAS”. O Art.3º diz que “Compete ao Ministério do Meio Ambiente (MMA), ao Ministério da Economia e aos Ministérios setoriais relacionados, quando houver, propor os Planos Setoriais de Mitigação das Mudanças Climáticas.” E que os PSMMC serão aprovados por um comitê interministerial sobre mudanças climáticas e crescimento verde, previsto pelo Decreto nº 10.845, de 25 de outubro de 2021.

Ele também compete que os PSMMC serão responsáveis pelo estabelecimento de metas de redução de emissão de gases do efeito estufa, de maneira mensurável e verificável, essas metas são de longo prazo, e procuram a neutralidade climática. Para atingirmos essas metas devemos monitorar por meio de inventários de GEE, todas as informações serão posteriormente repassadas para o NDC, em periódicos que serão definidos para cada plano.

O Art 7º, último do Capítulo II, cita que o Mercado Brasileiro de Redução de Emissões será um instrumento muito importante para controle e divulgação dos dados. Essa será uma ferramenta para implementação dos compromissos de redução de emissões mediante a utilização e transação dos créditos certificados de redução. Esse tem o potencial de ser o maior meio de transações de créditos ambientais no Brasil.

O Capítulo terceiro é nomeado “DO SISTEMA NACIONAL DE REDUÇÃO DE EMISSÕES DE GASES DO EFEITO ESTUFA”. Ele institui o sistema e o nomeia com a sigla Sinare. Esse sistema será responsável por servir como uma central de registros, contendo os dados das emissões, remoções, reduções e compensações de GEE, além dos atos de comércio, transferência e transações de créditos certificados de redução de emissão em território brasileiro.

O Artigo oitavo determina que fica por conta do Ministro de Estado do Meio Ambiente e da Economia estabelecer regras sobre o registro, o padrão de certificação que será aceito pelo Sinare, o credenciamento de empresas certificadoras e centrais de custódia; a implementação, operacionalização e como será a gestão do Sinare. Também deverá ser feito “o registro público e acessível por um ambiente virtual, com os projetos, iniciativas, e programas de geração de crédito certificado de redução de emissões e compensação de emissões de gases do efeito estufa.”

Os critérios para que outros gases do efeito estufa possam ser compatibilizados como créditos de carbono terão de ser reconhecidos pelo Sinare, por proposição do órgão ou entidade competente pelos ativos. Os créditos certificados por redução poderão ser comercializados ou utilizados no cumprimento das metas estabelecidas pelo Sinare.

O Sinare será fornecido através de uma plataforma virtual online. A administração desta plataforma está atribuída ao Ministério do Meio Ambiente. Mas para o estabelecimento de mecanismos de compatibilização com o Sistema de Registro Nacional de Emissões, será de responsabilidade de um ato conjunto entre os ministros de Estado das pastas do Meio Ambiente, Economia e, Ciência e Tecnologia e Inovações.

A plataforma do Sinare será responsável por oferecer as ferramentas de registro para as emissões, remoções e reduções dos GEE, além de também ter o registro de atos de comércio, transferências, transações e da aposentadoria de crédito certificado de redução de emissões. Também fica por conta desse, a integração com o mercado regulado internacional sem quebrar nenhuma das regras já adotadas. Todo inventário de emissão e remoção dos gases também estará disponível nesta plataforma. Outras ferramentas importantes que o Sinare possuirá são, o registro de pegada de carbono de produtos, processos e atividades liberadoras de GEE, o carbono de vegetação nativa, o carbono do solo, o carbono azul (carbono retido na região costeira como manguezais, e nos oceanos) e unidade de estoque de carbono.

O Capítulo IV, é o último deste decreto e se chama, “DISPOSIÇÕES FINAIS”, define um prazo de cento e oitenta dias para apresentar as proposições de estabelecimento de curvas de redução de emissões, sempre tendo como objetivo de, ao longo prazo, alcançar a neutralidade climática.

Esse Decreto é o primeiro passo para que possamos ter uma lei que defina a maneira que o mercado brasileiro irá funcionar, com suas metas e objetivos definidos. Também é importante que os métodos de certificação estejam de acordo com os demais mercados para que, com isso, possamos passar mais credibilidade e valorizar nosso produto. Um decreto não passa tanta segurança quanto uma lei pois pode ser facilmente alterado enquanto a lei não.

2.4. Séries temporais

É muito importante termos ciência do que pode ocorrer no futuro, para que as melhores decisões sejam tomadas nos melhores momentos. Séries temporais são análises de uma variável ordenada, em intervalos regulares de tempo, com a finalidade de encontrar um resultado futuro perto da realidade. Sendo possível de utilizar em diversas situações, desde a medição da temperatura da Terra, até a variação do número de doentes durante os anos.

“A suposição básica que norteia a análise de séries temporais é que há um sistema causal mais ou menos constante, relacionado com o tempo, que exerceu influência sobre os dados no passado e pode continuar a fazê-lo no futuro.”(LATORRE, 2001). Esse tipo de técnica procura produzir padrões não aleatórios que possam ser detectados em gráficos. Ao

definirmos esse padrão de variação podemos inferir resultados futuros para a variável de estudo, orientando aquele que o faz, nas suas tomadas de decisões.

3. MATERIAL E MÉTODOS

3.1. Base de dados

Os dados foram obtidos pela plataforma International Carbon Action Partnership (ICAP). Para a composição do conjunto de dados, foram retiradas informações de 25/03/2008 até 10/02/2023. Essa plataforma disponibiliza o preço de diversos mercados de carbono, tanto em Euro como em Dólar. As informações contêm os valores diários, com exceção dos fins de semana, já que durante esses dias não há funcionamento do mercado que comercializa o crédito. Através dos dados baixados, foi filtrado o preço em Euro da bola de nosso interesse e com o uso do software Google Sheets os dados foram organizados sendo retirados as datas de sábado e domingo. Para modelagem da série foi utilizado o valor médio do mês.

Os dados foram importados para o software R, e por meio de pacotes contidos dentro desse fizemos a previsão, pelos métodos de ARIMA, *Prophet* e *Random Forest*.

3.2. Previsão do preço do crédito de carbono

Os modelos de previsão são criados a partir de uma infinidade de dados coletados em um intervalo de tempo conhecido e constante. Para estimar valores futuros em uma série temporal é necessário que dentro dessa série seja possível captar e modelar matematicamente de uma maneira representativa aos dados analisados na série temporal.

Existem milhares de modelos matemáticos adequados para as mais diversas finalidades. Essas, são fundamentais para a tomada de decisão de situações futuras facilitando e otimizando o processo de produção, distribuição, armazenamento, planejamento, entre muitas outras minúcias que possam ser mensuradas e processadas dentro de um modelo. Deste modo, neste trabalho optou-se por diferentes estratégias de diagnóstico, para definir qual o melhor método na previsão do crédito de carbono. Assim, foram utilizados os modelos ARIMA, *Prophet* e *Random Forest*. Todos os modelos foram processados utilizando os pacotes “pacman”, “tidyverse”, “forecast”, “tidyquant”, “timetk”, “modeltime”, “tidymodels” e “workflows”, utilizando o software R (R CORE TEAM, 2020). Todo código utilizado para a modelagem neste trabalho está disponível no anexo 1.

Os modelos utilizaram todos os dados obtidos, exceto os últimos seis meses para treinamento. Os valores dos últimos seis meses foram utilizados apenas para comparação dos valores reais com os estimados.

3.3. ARIMA

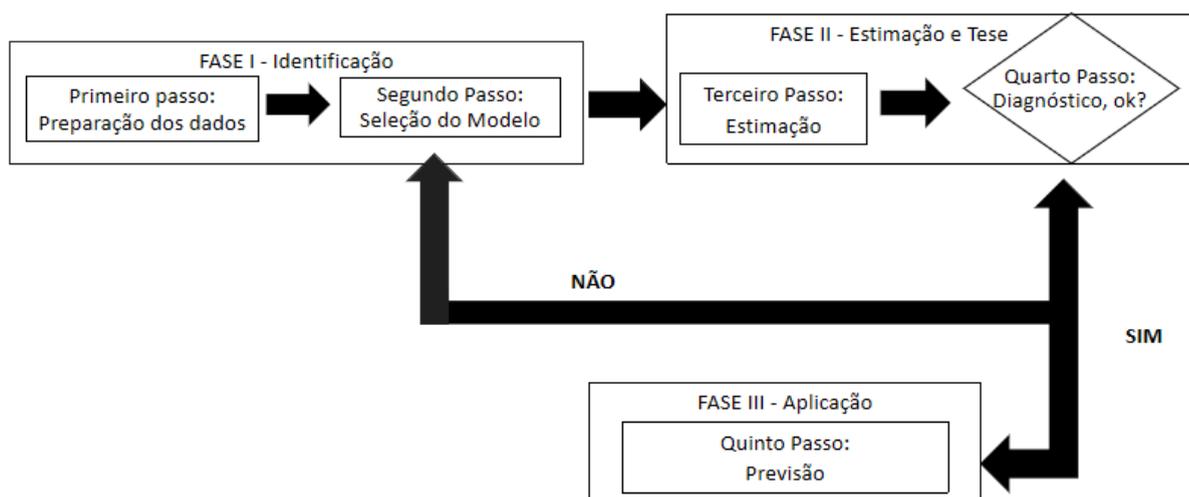
Esse não possui uma análise temporal tão profunda quanto a do *Prophet*.

“O processo ARIMA são modelos matemáticos utilizados para previsões. ARIMA é um acrônimo para Auto Regressivo (AR), Integrado (I) e Média Móvel (MA). Cada um desses descreve uma parte diferente da criação do modelo.”(HYNDMAN, 2001)

O *Autoregressive Integrated Moving Average* - ARIMA (p,d,q) foi desenvolvido em 1970 por Box & Jenkins, é um modelo utilizado principalmente para séries temporais não estacionárias, aquelas em que a média, variância, não são constantes ao longo do tempo. Esse método procura descrever séries em que a média não é constante (BOX, 1970).

O método ARIMA utiliza uma metodologia empírica que, de acordo com Makridakis *et al.* (1998), pode ser descrita em três fases com cinco passos no total, a imagem abaixo mostra as fases e os passos dentro de cada uma dessas (BOX, 1994). O fluxograma 1 abaixo, demonstra os passos feitos pelo método.

Figura 4 : Fluxograma da metodologia ARIMA.



Fonte: Makridakis *et al.* (1998) e DeLurgio (1998) - Modificado.

3.4. Prophet

O *Prophet* é um algoritmo desenvolvido pela empresa Meta como ferramenta de estudo de algumas de suas plataformas. Em 2017 essa ferramenta foi disponibilizada publicamente. Através de parâmetros definidos por nós, esse algoritmo é capaz de captar as

sazonalidades dentro dos dados. Essa ferramenta está disponível para uso na plataforma do R e Python (TAYLOR; LETHAM, 2017).

Esse algoritmo foi lançado com a função de ajudar desenvolvedores, analistas de dados, e qualquer pessoa que deseja fazer um planejamento de longo prazo, sendo possível estabelecer um melhor planejamento futuro, com os dados obtidos dele.

Esse algoritmo tem como base para um bom funcionamento, uma grande base de dados de meses ou anos com o maior detalhamento possível, uma sazonalidade forte e destacada, tendência de crescimento não linear, que se aproxima de algum limite. O software também é capaz de reconhecer feriados, e datas especiais conhecidas. O grande diferencial deste, comparado com os restantes, é o reconhecimento das sazonalidades em datas especiais. Esse ponto é muito importante para estudo de vendas em feriados, por exemplo.

Em sua essência o *Prophet* trabalha em um modelo de regressão aditivo com quatro componentes principais, eles são: um componente sazonal modelado pela série de Fourier, uma tendência de crescimento linear na curva, o Prophet detecta automaticamente as tendências selecionando pontos em que a curva muda de direção, e um componente sazonal semanal que utilize variáveis fictícias e uma lista de feriados fornecidas pelo usuário (TAYLOR; LETHAM, 2017).

3.5. Random forest

O *Random Forest* é definido por Leo Breiman (2001) como, “uma combinação de árvores de previsão tal qual cada árvore depende de valores de um vetor aleatório amostrado independentemente e com a mesma distribuição para todas as árvores da floresta. Os erros da generalização para as florestas se convertem para um limite assim que o número de árvores aumenta.”

Para construção de cada árvore o algoritmo seleciona uma variável e a divide em duas saídas chamada ramos ela analisa cada saída de ramo estudando seus possíveis valores, com isso cria limites numéricos para cada variável. Esse método é bem utilizado quando encontramos diversas variáveis em um problema. Pois ele conseguirá estabelecer quais melhores variáveis serão consideradas na formulação das árvores de decisões. Neste trabalho foram construído um total de 500 árvores de decisão

3.6. Métricas de avaliação

Já para comparar os modelos testados no presente estudo, é importante diagnosticar a capacidade preditiva dos modelos. Assim, utilizou-se métricas associadas ao erro, sendo: (i)

erro médio absoluto, (“Mean absolute error”, MAE) ele faz a média da diferença entre o real e as previsões e (ii) O erro percentual médio absoluto, (“Mean absolute percentage error” MAPE) mede o erro em forma de porcentagem. (iii) O Erro Percentual Absoluto, (“Symmetric mean absolute percentage” sMAPE) é baseado na porcentagem de erro. (iv) O erro médio absoluto escalado, (“Mean absolute scaled error”, MASE) é utilizado para medir a precisão das previsões. e (v) A raiz quadrada média do erro, (“Root Mean Square Error”, RMSE) corresponde à raiz quadrada do erro conforme disposto na Tabela 1. (vi) O coeficiente de determinação, (R^2) nos diz quão perto os valores previstos estão do real, e seu valor é em porcentagem, na maioria das vezes quanto mais próximo de 1 melhor.

Tabela 1 - Critérios de seleção dos modelos no processo de validação.

Estadísticas	Critérios de Seleção	Equação Matemática
	MAE	$\frac{100\%}{n} \sum_{t=1}^n \left \frac{e_t^2}{y_t} \right $
	MAPE	$\frac{1}{n} \sum_{t=1}^n e_t $
	sMAPE	$\frac{2}{n} \sum_{i=1}^n \frac{ y_i - \hat{y}_i }{ y_i + \hat{y}_i }$
	MASE	$\frac{e_t}{\frac{1}{n-1} \sum_{i=2}^n y_i - y_{i-1} }$
	RMSE	$\sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2}$
	R^2	$\frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2}$

Em que: n: número de observações; t: sub-índice das observações; e: erro; y: valor observado da variável dependente.

Fonte: do autor (2023)

4. RESULTADOS

Abaixo, na tabela 1 temos algumas métricas e resultados estatísticos de erro dos algoritmos de modelagem aplicados neste trabalho, utilizando os dados de preço de carbono EU-ETS.

Tabela 2 - Métricas de avaliação dos modelos testados.

Modelo	MAE	MAPE(%)	SMAPE	MASE	RMSE	R ²
ARIMA (1,0,0)	17,05	19,25	21,8	1,93	19,19	0,87
Prophet	6,75	7,9	8,14	0,76	7,53	0,68
Random Forest	12,68	14,26	15,62	1,43	14,73	0,42

MAE: erro médio absoluto; MAPE: erro percentual médio absoluto; SMAPE: Erro percentual absoluto; MASE: Erro médio absoluto; RMSE: desvio médio quadrático; R²: Coeficiente de determinação.

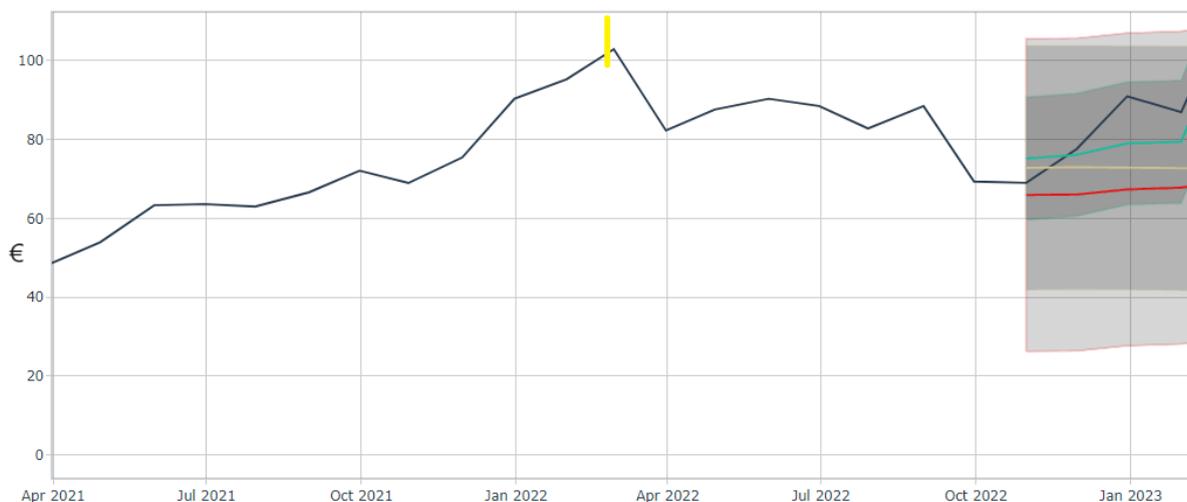
Fonte: do autor (2023).

Foram utilizadas seis métricas diferentes para comparar os modelos utilizados dentre as métricas observadas, o ARIMA obteve os maiores valores de erro em todas as medidas, enquanto o *Prophet* obteve os menores, o modelo Random Forest obteve o menor coeficiente de determinação entre os três modelos estudados.

Na figura 5, são observadas as previsões dos modelos para o período de 31/10/2022 a 10/02/2023. No modelo ARIMA, pode-se observar que houve pouca variação no valor do modelo, estando sempre distante da realidade. Já para o modelo *Prophet* é observado que os resultados conseguiram acompanhar melhor as ondulações dos valores na série, quando comparado com o método ARIMA e *Random Forest*.

Mesmo com a perda de precisão dos modelos com o passar do tempo, o valor final ficou próximo ao real para o modelo *Prophet*, enquanto as variações do *Random Forest* e ARIMA foram pequenas quando comparadas, não acompanhando os valores reais.

Figura 5. Resultado dos algoritmos aplicados.



-Valor real; -ARIMA; -Prophet; -Random Forest | Início da invasão Russa a Ucrânia.

Fonte: do autor (2023).

O fato de uma guerra ter iniciado foi responsável por uma enorme desvalorização no preço do crédito. Isso evidencia que devemos estar atentos às condições externas e como essas podem afetar no momento da precificação do crédito, as condições vigentes das políticas internacionais devem sempre ser levadas em consideração no momento de tomada de decisão de compra ou venda do crédito. A previsão real da variação deve sempre ser estabelecida considerando fatores externos, fatores esses que os modelos não são capazes de prever. Ter conhecimento de como o preço varia de acordo com essas situações, e estar atualizado sobre quando elas podem ocorrer dão grande vantagem para aquele que pretende comprar ou vender créditos em um momento em que seu objetivo será otimizado.

5. DISCUSSÃO

O mercado de carbono vem em um ritmo de crescimento, mesmo com o valor passando por diversas crises, em uma visão de longo prazo conseguimos identificar uma tendência de crescimento. Estudos de eficiência sobre os modelos usados são de extrema importância para que os gestores tenham maior adequação dos recursos disponíveis através de um planejamento com previsões mais seguras e eficientes. Porém, vale ressaltar que a eficiência de cada modelo é diretamente influenciada pelos dados obtidos e utilizados, portanto é sempre recomendado testar mais de um modelo a fim de avaliar a adequação dos modelos para cada tipo de dado.

Entre os três métodos utilizados, aquele que obteve capacidade mais baixa de previsão foi o ARIMA com os maiores valores em todos os erros estudados. O modelo ARIMA mesmo obtendo as piores métricas entre os modelos testados apresentou o maior coeficiente de determinação. O trabalho de Sah em 2022 obteve resultado similar, em que o modelo *Prophet* apresentou um menor erro e também menor coeficiente de determinação. Sardar em 2022 realizou um estudo em que se tentava prever a quantidade de infectados por covid em países do sul da Ásiático, conseguiu validações diferentes para cada país, em alguns casos o ARIMA obteve menor erro enquanto em alguns outros o *Prophet* teve melhores resultados demonstrando que nem sempre um mesmo modelo será o melhor que os demais.

O modelo com as melhores métricas obtidas foi o *Prophet*, este apresentou os menores erros; *Random Forest* e ARIMA não conseguiram prever a variação do preço o que ocasionou em um maior distanciamento com a realidade e erro. Porém Petukhova em um estudo sobre contaminação *influenza A.* em suínos em 2018 comparou através dos modelos ARIMA e *Random Forest* uma análise de previsão de diagnóstico e contagem de casos. No teste de previsão do diagnóstico, o modelo *Random Forest* se mostrou com melhor ajustamento com os dados reais. No estudo também foi constatado que, diferentemente deste, em momentos de acelerado crescimento de casos o modelo ARIMA obteve melhor ajuste na análise dos dados.

A ARIMA utiliza principalmente da variação da média móvel para atingir o resultado, sem levar em consideração as variações sazonais ocorridas nos dados. O algoritmo do *Random Forest* procura padrões de resposta através das variáveis dispostas e a partir deles montar árvores de decisão através da regressão dos dados fornecidos. Enquanto o *Prophet* tem uma maior afinidade em identificar padrões temporais.

Talvez um período de testes mais abrangente possa trazer melhores resultados tanto para ARIMA quanto para o *Random Forest*, já que em muitos dos seus testes positivos possuíam um maior intervalo de tempo em testes. É o caso de Kane que em 2014 estudou ambos os modelos para a doença aviária H_5N_1 no intervalo de 2007 a 2013, ambos os modelos tiveram boas respostas sendo que o *Random Forest* também atingiu melhores métricas que o ARIMA.

É de grande importância sabermos quando variações podem ocorrer ao longo do tempo para otimizar processos e promover tomada de decisões mais adequadas. Os modelos

que conseguem fazer esse tipo de previsão acabam tendo melhores resultados pois os valores terão menor oscilação estando mais próximos da realidade, além de informar sobre uma possível alteração positiva ou negativa do valor real.

6. CONCLUSÃO

Dos três modelos estudados o *Prophet* foi o que obteve um melhor resultado, por ter a capacidade de prever com maior precisão os momentos de ondulação durante o período estudado, além de ter o valor mais próximo do real na maior parte do tempo. Os demais modelos não variaram com o valor real e apenas se distanciaram, não sendo os recomendados para esse tipo de análise.

O reconhecimento da sazonalidade é uma das principais informações que procuramos conhecer, pois é através dela que teremos um diferencial de informação para a tomada de decisão. O fato de o ARIMA e o *Random Forest* não terem sido capazes de reconhecer a sazonalidade diminui a sua prioridade de uso em relação ao *Prophet*. Importante ressaltar que estes não deixam de ser uma opção de modelos de previsão, já que esse tipo de modelo obteve ótimos resultados em outros tipos de análise.

Com a chegada em um futuro próximo de um mercado brasileiro de créditos de carbono acredito que o gestor que tiver o conhecimento dessa ferramenta e suas utilidades estará em vantagem em relação aos outros.

REFERÊNCIAS

ACTION, Climate. The EU emissions trading system (EU-ETS). 2013.

Brasil, Ministério da ciência tecnologia e inovação. Acordo de Paris. [Brasília]: Ministério da ciência tecnologia e inovação, 29/06/2021 Disponível em: <https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/sirene/publicacoes/acordo-de-paris-e-ndc/acordo-de-paris>. Acesso em 11/03/2023

BREIMAN, Leo. Random forests. **Machine learning**, v. 45, p. 5-32, 2001.

BOX, George EP; JENKINS, Gwilym M.; REINSEL, G. C. Time series analysis, forecasting and control. Englewood Clifs. 1994.

BOX, George EP; PIERCE, David A. Distribution of residual autocorrelations in autoregressive-integrated moving average time series models. **Journal of the American Statistical Association**, v. 65, n. 332, p. 1509-1526, 1970.

CHANGE, IPCC Climate et al. Mitigation of climate change. **Contribution of working group III to the fifth assessment report of the intergovernmental panel on climate change**, v. 1454, p. 147, 2014.

CRIPPA, Monica et al. GHG emissions of all world countries. **Publications Office of the European Union**. <https://publications.jrc.ec.europa.eu/repository/handle/JRC126363>, 2021.

EUROPEAN COMMISSION, **Development of EU ETS (2005-2020)**, Disponível em: https://climate.ec.europa.eu/eu-action/eu-emissions-trading-system-eu-ets/development-eu-ets-2005-2020_en#first-steps>. Acesso em: 10/03/2023.

FEDERAL, Senado. Protocolo de Quioto e legislação correlata. **Brasília: Senado Federal**, 2004.

GURSKI, Bruno; GONZAGA, Roberto; TENDOLINI, Patricia. Conferência de Estocolmo: um marco na questão ambiental. **Administração de Empresas em Revista**, v. 1, n. 7, p. 65-79, 2012.

HYNDMAN, Rob J. ARIMA processes. **Datajobs: Data science knowledge**, 2001.

IEA. Global Energy Review: CO2 Emissions in 2021-Global Emissions Rebound Sharply to Highest Ever Level. 2022.

KANE, Michael J. et al. Comparison of ARIMA and Random Forest time series models for prediction of avian influenza H5N1 outbreaks. **BMC bioinformatics**, v. 15, n. 1, p. 1-9, 2014.

Kyoto Protocol. **International Legal Materials**, v. 37, n. 1, p. 22-43, 1998.

LATORRE, Maria do Rosário Dias de Oliveira; CARDOSO, Maria Regina Alves. Análise de séries temporais em epidemiologia: uma introdução sobre os aspectos metodológicos. **Revista Brasileira de Epidemiologia**, v. 4, p. 145-152, 2001.

LE QUÉRÉ, Corinne et al. Fossil CO2 emissions in the post-COVID-19 era. **Nature Climate Change**, v. 11, n. 3, p. 197-199, 2021.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYDMAN R. J. (1998). **Forecasting methods and applications**. 3th edition. New Jersey: John Wiley & Sons. 642p.

MCGIVERN, Brendan P. Conference of the Parties to the Framework Convention on Climate Change: Kyoto Protocol. **International Legal Materials**, v. 37, n. 1, p. 22-43, 1998.

MITCHIE, Roa et al. Entity-level Greenhouse Gas Emission of University of Science and Technology of Southern Philippines-Oroquieta. **American Journal of Environment and Climate**, v. 1, n. 3, p. 6-11, 2022.

PAN, Yude et al. A large and persistent carbon sink in the world's forests. **Science**, v. 333, n. 6045, p. 988-993, 2011.

PETUKHOVA, Tatiana et al. Assessment of autoregressive integrated moving average (ARIMA), generalized linear autoregressive moving average (GLARMA), and random forest (RF) time series regression models for predicting influenza A virus frequency in swine in Ontario, Canada. **PloS one**, v. 13, n. 6, p. e0198313, 2018.

REIS, Marcelo Menezes. Estatística aplicada à Administração. **Florianópolis, SC: Departamento de Ciências da Administração-UFSC**, 2008.

SAH, Sweeti et al. Forecasting COVID-19 pandemic using Prophet, ARIMA, and hybrid stacked LSTM-GRU models in India. **Computational and Mathematical Methods in Medicine**, v. 2022, 2022.

R CORE TEAM. **R: A language and environment for statistical computing** Vienna R Foundation for Statistical Computing, , 2020.

SARDAR, Iqra et al. Machine learning and automatic ARIMA/Prophet models-based

forecasting of COVID-19: methodology, evaluation, and case study in SAARC countries. **Stochastic Environmental Research and Risk Assessment**, p. 1-15, 2022.

Taylor SJ, Letham B. 2017. Forecasting at scale. *PeerJ Preprints* 5:e3190v2

TAYLOR, Sean J.; LETHAM, Benjamin. Forecasting at scale. **The American Statistician**, v. 72, n. 1, p. 37-45, 2018.

WOLFFENBÜTTEL, Andréia. O que é? IPCC. **Instituto de Pesquisa em Economia Aplicada (IPEA)**. Ano 4 . Edição 34 -2007.

ANEXO 1 - Código utilizado para a modelagem de previsão.

```

# install.packages("pacman")

pacman::p_load(tidyverse,forecast,tidyquant,timetk,modeltime,tidymodels,workflows)

# Entrada de Dados -----
dados = read.table("dados.txt",header = T, sep = "\t")

mdados = dados[,c(1,2)]

mdados$Date = as.Date(mdados$Date,format = "%d/%m/%Y") # Ele muda a estrutura da
data no arquivo de entrada

glimpse(mdados)

mdados = mdados[order(mdados$Date, decreasing = F),] %>%
  mutate(Price = Price) # um teste com variavel em log

Carbono = as.xts(mdados$Price, mdados$Date)

# Descobrir a frequência de forma automatizada

mdados %>%
  tk_index() %>%
  tk_get_frequency(period = "auto")

# converter para semana

df_semanal <- mdados %>% tq_transmute(select = Price, mutate_fun = apply.monthly,
FUN = mean)

df_semanal %>% head()

# Gráfico da série temporal

# A série semanal parece ter alguns padrões de tendência.

df_semanal %>%
  plot_time_series(Date, Price)

# codigo alternativo

mdados %>%
  ggplot(aes(x = Date, y = Price)) +
  geom_line()

# Para investigar vamos usar plot_stl_diagnostics.

# Alternativamente pode-se utilizar a função decompose.

df_semanal %>%

```

```

plot_stl_diagnostics(Date, Price, .frequency = "auto", .trend = "auto")
ts_split <- df_semanal %>%

time_series_split(assess = "6 months", # últimos 6 meses como testing set
cumulative = TRUE) # todos os períodos anteriores como training set
ts_split %>%

tk_time_series_cv_plan() %>%

plot_time_series_cv_plan(Date, Price)
recipe_auto <- recipe(Price ~ Date, data = training(ts_split))
recipe_spec <- recipe(Price ~ Date, data = training(ts_split)) %>%

step_timeseries_signature(Date) %>%

step_fourier(Date, period = c(12, 24, 36, 48), K=2) %>%

step_rm(contains("iso"), contains("minute"), contains("hour"),
contains("am.pm"), contains("xts")) %>%

step_date(Date, features = "month", ordinal = FALSE) %>%

step_mutate(date_num = as.numeric(Date)) %>%

step_normalize(date_num) %>%

step_normalize(contains("index.num")) %>%

step_dummy(contains("lbl"), one_hot = TRUE) %>%

step_dummy(all_nominal())

bake(prepare(recipe_spec), new_data = training(ts_split))

# Modelo 1: ARIMA -----
modelo_fit_arima <- arima_reg() %>%

set_engine(engine = "auto_arima")

workflow_fit_arima <- workflow() %>%

add_recipe(recipe_auto) %>%

add_model(modelo_fit_arima) %>%

fit(training(ts_split))

# Modelo 2: PROPHET -----
modelo_fit_prophet <- prophet_reg(seasonality_yearly = TRUE) %>%

set_engine(engine = "prophet")

workflow_fit_prophet <- workflow() %>%

```

```

add_model(modelo_fit_prophet) %>%
add_recipe(recipe_auto) %>%
fit(training(ts_split))

# Modelo 3: Modelo de Random Forest -----
modelo_fit_rf <- rand_forest(trees = 500, min_n = 50) %>%
  set_mode("regression") %>%
  set_engine(engine = "randomForest")
workflow_fit_rf <- workflow() %>%
  add_model(modelo_fit_rf) %>%
  add_recipe(recipe_spec) %>%
  fit(training(ts_split))

# Adicionar Modelos Ajustados -----
tabela_modelos <- modeltime_table( workflow_fit_arima, workflow_fit_prophet,
  workflow_fit_rf)
tabela_modelos

# Calibração dos Modelos -----
tabela_calibacao <- tabela_modelos %>%
  modeltime_calibrate(new_data = testing(ts_split))
tabela_calibacao

# Visualizar a Previsão -----
tabela_calibacao %>%
  modeltime_forecast(
    new_data = testing(ts_split),
    actual_data = df_semanal) %>%
  plot_modeltime_forecast()

# Medidas de Performance -----
tabela_calibacao %>%
  modeltime_accuracy() %>%
  table_modeltime_accuracy()

# Reajustar o modelo -----
tabela_refit <- tabela_calibacao %>%

```

```
modeltime_refit(data = df_semanal)
tabela_refit %>%
  modeltime_forecast(h = "6 months", actual_data = df_semanal) %>%
  plot_modeltime_forecast()
resamples_tscv <- df_semanal %>%
  time_series_cv(initial = "12 months", # training window
                 assess = "6 months", # assessment window
                 skip = "6 months", # shift between resample sets
                 slice_limit = 4) # no. of resamples
resamples_tscv %>%
  tk_time_series_cv_plan() %>%
  plot_time_series_cv_plan(Date, Price)
library(modeltime.resample)
resamples_fitted <- tabela_modelos %>% modeltime_fit_resamples( resamples =
  esamples_tscv,(control = control_resamples(verbose = FALSE)
resamples_fitted %>%
  plot_modeltime_resamples(.point_size = 3, .point_alpha = 0.8,.interactive = FALSE )
```