

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ADMINISTRAÇÃO
DEPARTAMENTO DE CIÊNCIAS ADMINISTRATIVAS

GABRIELLE LIPPERT BONAZZA

**PREVISÃO DE RISCO NO MERCADO DE CRÉDITOS DE
CARBONO**

Porto Alegre

2022

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

GABRIELLE LIPPERT BONAZZA

**PREVISÃO DE RISCO NO MERCADO DE CRÉDITOS DE
CARBONO**

Trabalho de Conclusão de Curso
apresentado à Escola de Administração da
Universidade Federal do Rio Grande do Sul
como requisito básico para obtenção do
grau de bacharel em Administração.

Orientadora: Profa. Dra. Fernanda Maria
Müller

Porto Alegre

2022

GABRIELLE LIPPERT BONAZZA

PREVISÃO DE RISCO NO MERCADO DE CRÉDITOS DE CARBONO

Trabalho de Conclusão de Curso
apresentado à Escola de Administração da
Universidade Federal do Rio Grande do Sul
como requisito básico para obtenção do
grau de bacharel em Administração.

Profa. Dra. Fernanda Maria Müller (Orientadora)

Prof. Dr. Marcelo Brutti Righi (Avaliador)

Prof. Dr. Pablo Cristini Guedes (Avaliador)

Porto Alegre

2022

RESUMO

Sistemas de comércio de créditos de carbono têm sido implementados no mundo todo como forma de endereçar a crise climática. Nesse contexto, o entendimento sobre os riscos envolvidos nesses mercados é determinante para uma gestão e regulamentação mais adequadas, o que contribui para a sua manutenção e a efetiva redução das emissões de carbono. Dessa forma, tomando os dados dos retornos de créditos de carbono do Sistema Europeu de Comércio de Emissões (EU-ETS), esse estudo computou as previsões do Valor em Risco (VaR) e da Perda Esperada (ES), considerando diferentes distribuições de probabilidade para o termo aleatório do modelo ARMA-GARCH. Foram empregadas oito distribuições diferentes e considerados dois níveis de significância, 1% e 5%, para gerar previsões de ambas medidas um passo à frente com janela de estimação rolante de 250 e 1000 observações. As previsões foram avaliadas através da Perda Realizada. Os resultados sugerem que as distribuições *t* de Student e Generalizada do Erro são as mais indicadas para previsão de risco desse mercado, enquanto que as distribuições Normal e Empírica obtiveram desempenho ruim. Esses resultados contribuem para o manejo de risco de carbono nas empresas, promovendo tomadas de decisão mais acuradas diante do cenário de mudanças ambientais.

Palavras-chave: Créditos de carbono; Previsão de risco; VaR; ES; Distribuições.

ABSTRACT

Carbon credit trading systems have been implemented around the world as a way to address the climate crisis. In this context, understanding the risks involved in these markets is crucial for more accurate management and regulation, contributing to their maintenance and the effective reduction of carbon emissions. In this way, taking the data of the carbon credits returns from the European Union Emissions Trading System (EU-ETS), this study computed the predictions of Value-at-Risk (VaR) and Expected Shortfall (ES), considering different probability distributions for the random term of the ARMA-GARCH model. Eight different distributions were used and two levels of significance, 1% and 5%, were considered to generate one-step-ahead predictions of both measures with a rolling estimation window of 250 and 1000 observations. Forecasts were evaluated using Loss. The results suggest that the Student's t and Generalized Error distributions are the most suitable for predicting risk in this market, while the Normal and Empirical distributions performed poorly. These results contribute to the management of carbon risk in companies, promoting more accurate decision-making in the face of the scenario of environmental changes.

Keywords: Carbon credits; Risk Forecast; VaR; ES; Distributions.

SUMÁRIO

1. INTRODUÇÃO.....	7
2. REVISÃO BIBLIOGRÁFICA.....	11
2.1 OS MERCADOS DE CRÉDITOS DE CARBONO.....	11
2.2 EMISSÕES DE CARBONO E OS RISCOS.....	14
2.2.1 RISCO DE MERCADO NOS SISTEMAS DE COMÉRCIO DE CARBONO.....	16
3. PROCEDIMENTOS METODOLÓGICOS.....	19
4. RESULTADOS.....	21
5. CONCLUSÃO.....	29
REFERÊNCIAS.....	30

1. INTRODUÇÃO

Diante dos desafios climáticos e dos acordos recentes para redução das emissões de gases de efeito estufa (GEE), diversos países têm implementado e mantido mercados de títulos de carbono como forma de precificar as emissões da indústria e de outros atores econômicos. Tais mercados são fortemente regulados e têm por objetivo incentivar a transição para uma produção mais sustentável, apostando na premissa de que as emissões devem ser reduzidas primeiro nos nichos onde esse processo é menos custoso, gerando uma ótima alocação de recursos (WANG; WANG, 2015). Assim, as Reduções Certificadas de Emissão (CERs, na sigla em inglês), que correspondem a uma tonelada de carbono não emitida ou capturada da atmosfera, são trocadas comercialmente entre empresas ou projetos que comprovaram sua redução e indústrias que excederam os limites estipulados de emissão, em um sistema de compensações (IHS MARKIT, 2020).

Embora a eficácia dessas iniciativas para a redução das emissões esteja ainda sendo amplamente debatida tanto na comunidade científica quanto na sociedade (PATT; LILLIESTAM, 2019; KAUFMAN et. al., 2020; LOHMANN, 2009), os sistemas de trocas de créditos de carbono são um dos principais mecanismos utilizados para o endereçamento da crise climática pela política internacional (WANG; WANG, 2015). Mesmo que as CERs tenham gerado uma padronização capaz de transformar as emissões em títulos comercializáveis, os créditos de carbono compõem uma *commodity* bastante específica, cujas particularidades promovem diferenças de comportamento em relação a outros produtos financeiros, como o maior impacto das instabilidades ambientais externas, fatores políticos e eventos para discussão do clima (FENG; WEI; WANG, 2012). Soma-se a isso, ainda, o rápido crescimento do volume de negociações e da participação de intermediários financeiros, prestadores de serviços e especuladores, o que aumenta a complexidade e a volatilidade desses mercados (JIAO; LIAO; ZHOU, 2018), contribuindo para os desafios e incertezas em relação ao seu entendimento e à sua previsão.

A partir das fragilidades observadas no funcionamento dos mercados, as instituições governamentais frequentemente propõem mecanismos para aumentar a confiança dos atores envolvidos e a previsibilidade dos preços dos créditos (WANG; WANG, 2016), uma vez que um alto risco pode afetar de forma determinante esses mercados nascentes. Feng, Wei e Wang (2012), por exemplo, trazem que tanto o risco de queda quanto o de aumento nos preços

precisam ser controlados para a boa eficiência das trocas de créditos, ao contrário de outros mercados financeiros. Já Jiao, Liao e Zhou (2018) sublinham a importância que a previsão de risco tem para os diversos participantes dos mercados internacionais, por conta de sua característica procíclica que aumenta a volatilidade de preços, gerando uma necessidade de atenção especial para o manejo de risco nos mercados de carbono.

Diante da necessidade de previsão e entendimento sobre o risco desses mercados para seu funcionamento adequado e, em última análise, para o efetivo alcance de seu primeiro objetivo de reduzir as emissões, muitos estudos têm se debruçado sobre a questão. Verifica-se que boa parte desses estudos utilizam Valor em Risco (VaR) como forma de quantificar os riscos desses mercados. O VaR é definido como a máxima perda esperada em uma certa posição financeira, dados um certo período de tempo e um nível de confiança (CHRISTOFFERSEN, 2012). Paolella e Taschini (2008), utilizando o VaR quantificado por meio do modelo de Heteroscedasticidade Condicional Autorregressivo Generalizado (GARCH), encontraram que esse modelo providencia previsões acuradas do VaR para o mercado de licenças de emissão de carbono.

Ainda em outro estudo, Dutta et. al. (2020) investigaram o efeito de quebras estruturais na variância condicional dos preços de licenças de emissão de carbono. Usando o modelo GARCH simétrico e duas variações assimétricas, os autores quantificam o VaR. Outros estudos que utilizam modelos da família GARCH para modelar dados de créditos de carbono podem ser encontrados em Benz e Trück (2009), Chevallier (2011) e Byun e Cho (2013). Contribuindo com outras metodologias, Jiao, Liao e Zhou (2018) investigaram uma abordagem dependente do estado econômico para mensurar o VaR do mercado de carbono, incorporando nos retornos informações de fundamentos macroeconômicos para modelar e prever o risco.

Apesar de o VaR possuir boas propriedades estatísticas, no entanto, algumas críticas são feitas a essa medida de risco, como ignorar as perdas além do quantil de interesse e não ser uma medida de risco coerente¹ no sentido proposto por Artzner et. al. (1999). Assim, uma alternativa complementar ao VaR é a Perda Esperada (ES). Essa medida é definida como o valor esperado das perdas dado que essas sejam maior que o VaR (CHRISTOFFERSEN, 2012). Utilizando um método semi-paramétrico, Fang e Cao (2021) mensuraram o risco nos

1 Segundo Artzner et. al. (1999), as propriedades de uma medida de risco coerente são invariância sob translação, homogeneidade positiva, subaditividade e monotonicidade. O VaR não apresenta subaditividade.

mercados de carbono europeu e chineses com ambas variáveis. Mesmo assim, ainda são poucos os estudos que, dentro desse contexto, optam por utilizar ES para melhor mensuração do risco.

Além do mais, podemos verificar que muitos estudos se concentram na utilização de diferentes modelos da família GARCH para modelar dados que pertencem ao mercado dos créditos de carbono. No entanto, como apontado por Garcia-Jorcano e Novales (2021), a performance das previsões de risco está associada à distribuição de probabilidade considerada para as inovações e os modelos apresentam um papel secundário nesse contexto. Diante disso, o objetivo desse trabalho é avaliar a distribuição de probabilidade mais acurada para realizar as previsões do VaR e da ES da série de retornos de créditos de carbono, utilizando dados do Sistema Europeu de Comércio de Emissões (EU-ETS), para o período de 18 de dezembro de 2013 a 14 de abril de 2021. As previsões de risco um passo à frente foram obtidas por meio de um modelo Autorregressivo de Médias Móveis (ARMA)-GARCH, que apresentou resultados competitivos para previsão de risco de créditos de carbono, como mostrado por Dutta et. al. (2020). As distribuições de probabilidade utilizadas foram a Normal, Normal Assimétrica, t de Student, t de Student Assimétrica, Generalizada do Erro, Generalizada do Erro Assimétrica, SU de Johnson e Empírica. Os níveis de significância avaliados foram 1% e 5%, enquanto que a janela de estimação rolante considerada correspondeu aos tamanhos amostrais de 250 e 1000 observações.

A contribuição desse estudo é investigar a distribuição de probabilidade que melhor se adequa às características da série proveniente do mercado de créditos de carbono. Até onde sabemos, não há nenhum estudo que avalie as previsões do VaR e da ES obtidas por meio do modelo GARCH considerando diferentes distribuições de probabilidade. Observamos que o foco da literatura tem sido a previsão do VaR e a avaliação de distintos modelos univariados, e não a escolha da distribuição a ser considerada para o termo da inovação, como pode ser visto, por exemplo, no estudo de Dutta et. al. (2020). Além disso, esse trabalho também pretende contribuir com a classe de estudos que investiga, dentre diferentes modelos e distribuições de probabilidade, qual é o mais acurado para realizar previsões de medidas de risco.

Um entendimento mais completo e atual possível sobre os riscos de mercado desses sistemas comerciais pode auxiliar as instituições reguladoras a desenvolverem e implementarem mecanismos de estabilidade eficazes, bem como agregar informações úteis

aos diversos atores envolvidos nesse mercado. A possibilidade de uma maior acuracidade das previsões contribui para o planejamento das empresas presentes nesses sistemas de comércio, melhorando sua organização e a capacidade de alocar os recursos de forma correta. Esse aproveitamento, por sua vez, contribui com a efetiva mudança para a promoção de sistemas sustentáveis.

2. REVISÃO BIBLIOGRÁFICA

Para começar, contextualizaremos o mercado de créditos de carbono, seu histórico e principais conceitos; em seguida, discutiremos os riscos envolvidos na emissão de GEE e o papel dos mercados na gestão dos riscos climáticos. Por fim, abordaremos as especificidades dos riscos de mercado dos créditos de carbono e resultados de pesquisas anteriores de mensuração e previsão das medidas de risco com dados desses sistemas.

2.1 O MERCADO DE CRÉDITOS DE CARBONO

Em primeiro lugar, que condições levam um gás atmosférico a ser passível de mensuração, precificação, certificação e comercialização? Segundo o reporte de 2020 do Banco Mundial, as precificações de carbono são iniciativas que colocam valor explícito nas emissões de gases de efeito estufa, expressas em unidade monetária por tonelada de equivalentes de dióxido de carbono (WORLD BANK, 2020). Tal quantificação, por sua vez, tem a vantagem de ser passível de comércio em diferentes partes do mundo pela característica dos gases de serem distribuídos homogeneamente na atmosfera, fazendo com que uma tonelada não emitida em um canto do mundo possa ser trocada por uma tonelada emitida a mais do outro lado (CRAMTON; MACKAY; OCKENFELS, 2017). Também outros gases de efeito estufa podem ser comparados, em termos de contribuição para o aquecimento global, ao dióxido de carbono – criando assim as equivalências de carbono e permitindo a padronização (CALEL, 2013).

Em 2020, contavam em 61 as iniciativas de precificação de carbono no mundo, cujas formas principais são a imposição de taxas nas emissões e os Sistemas de Comércio de Emissões (*Emission Trading Systems*, ou ETS) (IHS MARKIT, 2020). Os ETS são mercados controlados nos quais empresas que excedem as quantidades permitidas de poluição podem compensar seu impacto adquirindo e resgatando créditos previamente certificados de outras empresas ou entes econômicos que reduziram emissões ou capturaram dióxido de carbono da atmosfera (WORLD BANK, 2020). Além desses, existem ainda as formas de comercialização do chamado mercado voluntário, que podem ser compradas por quaisquer pessoas que queiram compensar emissões ou contribuir para a redução das mudanças climáticas (CONTE; KOTCHEN, 2010). Os créditos de carbono são, portanto, uma

padronização certificada dos gases que produzem efeito de aquecimento global, uma *commodity* criada especialmente para mitigar os efeitos da mudança do clima.

Embora haja infinitas maneiras de se financiar iniciativas que promovam a transição para formas de produção mais sustentáveis, os sistemas de comércio de créditos foram escolhidos pelo Protocolo de Kyoto por possibilitarem uma maneira flexível e eficiente de as empresas cumprirem suas obrigações legais de redução (IHS MARKIT, 2020). A ideia veio de outras práticas de mercados de emissões anteriores, em especial o esquema de comércio de dióxido de enxofre americano da década de 90, iniciativa que visava à redução de chuvas ácidas em todo o país (BRYANT, 2019). O entusiasmo com o que foi tido como um grande sucesso em tais experiências culminou na aprovação da agenda americana de uma forma liberal de esquema de mercado para endereçar a crise climática, em detrimento de outras propostas que fomentavam o incentivo de fundos de financiamento dos países em desenvolvimento (NEWELL; PIZER; RAIMI, 2013).

O principal pressuposto por trás da aprovação de um esquema global de comércio de emissões é o de eficiência de custos – antes das áreas em que é mais barato reduzir vendem créditos para os demais setores, fazendo com que a transição para zerar a resultante total de gases emitidos tenha o menor custo possível (LOHMANN, 2009). Ao mesmo tempo, monetizar a emissão de gases faz com que se torne mais caro produzir com combustíveis tradicionais, gerando um incentivo econômico para que as empresas invistam em energias renováveis (ICAP, 2021). De fato, essa e outras formas de precificação de carbono são citadas entre as iniciativas isoladas mais eficientes de combate à mudança climática (IHS MARKIT, 2020), enquanto os ETS são hoje os sistemas mais usados com esse intuito mundialmente (WANG; WANG, 2015).

Após a introdução desses mecanismos na discussão a nível planetário, ainda nos anos 2000 a Europa toma a frente e cria o primeiro sistema regional. O Sistema Europeu de Comércio de Emissões (*European Union Emissions Trading Systems*), ou EU-ETS, é hoje o maior em termos de volume de negociações e valores (WORLD BANK, 2020). Outros principais mercados mundiais são os da Califórnia e do Nordeste dos Estados Unidos que, junto com a Europa, têm o valor de 52 bilhões de dólares e negociaram aproximadamente 2,7 bilhões de toneladas de carbono no ano de 2020, contando com a maior liquidez dentre esses sistemas (ICAP, 2021). Iniciativas de sistemas de comércio também já existem no Canadá, Nova Zelândia, Coreia do Sul, entre outros. Mais recentemente, a China lançou em várias

idades mecanismos pilotos que ainda não estão totalmente consolidadas, mas que contam com grande expectativa já que o país é hoje um dos maiores emissores de GEE. Dessa forma, apenas a perspectiva de que 30% de suas emissões sejam cobertas por créditos nesse mercado já faria deles o maior do mundo (ICAP, 2021).

Apesar de todo o otimismo em torno dos mercados de créditos, muitas são as críticas e os paradoxos produzidos pela sua comercialização. Primeiro, os créditos são certificados com base em uma referência sobre a quantidade de gases que seriam emitidos se não houvesse determinada intervenção, o que nem sempre é fácil de estabelecer (LOHMANN, 2009), gerando pressuposições e arredondamentos que colocam em dúvida sua validade. Outras críticas se referem à corrupção de agentes envolvidos nas certificações e na falta de confiança na manutenção das ações redutoras cujos efeitos necessitam de um longo prazo (KAUFMAN et. al., 2020). E, para além das críticas em relação à validade dos créditos em si, existem muitas outras que questionam a eficiência de sua estrutura de comércio – se, ao serem capazes de compensar suas emissões, as empresas na verdade não teriam menos incentivos para implementar tecnologias limpas – e ainda, mais amplamente, se a proposta política de criar um mercado para dar conta de um problema resultante do próprio sistema de produção não seria uma contradição em termos (LOHMANN, 2009).

Independentemente da eficácia de tais mecanismos no endereçamento da crise climática, é certo que a criação de uma *commodity* estranha ao mercado coloca os créditos e o funcionamento de seu comércio em uma situação distinta da maioria dos sistemas financeiros. Feng, Wei e Wang (2012, p. 98) nomeiam os créditos de carbono como uma “*special commodity*”, ao citar que esses não se comportam como produtos financeiros normais, além de serem mais sensíveis a instabilidades políticas. Os autores trazem que a variação do preço dos créditos está mais relacionada com as expectativas de escassez desses no mercado; a oferta de licenças de carbono, diferentemente de outras *commodities*, é um frequente mecanismo de controle utilizado para regulamentação (CALEL, 2013).

Bryant (2019) discute que a criação de uma *commodity* para mitigar a mudança climática parte de uma ideia difundida na década de 1930 de que as mudanças climáticas e a degradação do ambiente seriam uma falha de mercado. Dessa forma, os benefícios privados do consumo de bens poluentes em seu processo fabril são menores que os custos sociais referentes a esse consumo – justamente porque tais custos não são incluídos na produção (BRYANT, 2019). Sendo tomado como externalidade, para resolver tal questão bastaria que

se integrasse, portanto, o problema ambiental aos mercados – exatamente o objetivo da criação dos créditos. Entretanto, apesar de ser uma ideia fundada em princípios liberais e na aposta de um funcionamento otimizado dos mecanismos de mercado, as experiências desde a criação dos sistemas de comércio têm mostrado que são necessárias intervenções importantes da parte dos estados para que as certificações de carbono tenham maiores chances de atender a esse primeiro objetivo (WANG; WANG, 2016), o que nos indica mais uma vez a complexidade da implementação de tais ações.

Já sabemos, portanto, o suficiente para entender que as *commodities* de carbono não são um produto tradicional e conseqüentemente não se comportam de tal forma. Diante de todas as contradições e os desafios do estabelecimento de uma mecânica de comércio que tenha efeitos reais na mitigação da crise climática, devemos olhar para essa tentativa de gerir os riscos do aquecimento global e compreender, de forma ampla, a diversidade de riscos que estão imbricados nesses mercados.

2.2 EMISSÕES DE CARBONO E OS RISCOS

Ao olhar para o histórico e a geografia das emissões de GEE, fica evidente o quanto a questão ambiental é fortemente marcada pela desigualdade social: os maiores poluidores não são aqueles sobre os quais recaem os maiores riscos climáticos (BRYANT, 2019). Mesmo assim, a crise do clima trará conseqüências em escala global, e as propostas para mitigá-la acompanham a tendência de que respostas regionais não darão conta do problema (IHS MARKIT, 2020). Diante desse quadro, não impressiona o fato de o início desse século ter produzido o que pode ser um de seus produtos mais curiosos, as compensações de carbono, como forma de manejar esse risco determinante e vários outros relacionados às suas medidas de contenção.

Pensar o mercado de créditos de carbono, em si, como formas de mitigação de riscos evidencia também uma outra abordagem atual – a de mensuração dos riscos de forma monetária. De fato, previsões de queda do PIB mundial já foram calculadas a partir dos estudos sobre o clima (BRYANT, 2019). Esses e outros diversos estudos procuram informar ao mercado, e à população de forma geral, como gerenciar o risco financeiro das mudanças que estão em curso, tanto em relação às climáticas quanto em relação aos efeitos de políticas públicas para reduzi-las. Assim, quantificar os riscos financeiramente permite-nos incorporá-

los a outros cálculos, bem como equipará-los com outros fatores decisórios. Entretanto, nem sempre é simples compreender um risco matematicamente. Danielsson (2011) explicita que um dos principais desafios em prever riscos financeiros é que esses não podem ser medidos diretamente, apenas inferidos, o que difere essa classe de risco de outras grandezas passíveis de observação direta como a temperatura. Mensurar os riscos com números, dessa forma, envolve necessariamente alguma dose de pressuposição (DANIELSSON, 2011).

Uma definição genérica para risco pode ser a chance de perder algo – e, em uma relação financeira, a chance de perder parte de um investimento (DANIELSSON, 2011). Righi (2019) aponta que a intuição do risco está relacionada a dois pilares: primeiro, a possibilidade de resultados negativos e, segundo, a variabilidade sobre um valor esperado. Uma das métricas mais utilizadas para avaliar a possibilidade de perdas é o VaR, cuja definição é justamente a máxima perda esperada em uma certa posição financeira, dado um certo período de tempo e um nível de confiança (MÜLLER; RIGHI, 2018). A ideia de perda é tão central no risco que uma das críticas a essa medida, ainda segundo Müller e Righi (2018), é não levar em conta as perdas para além dos quantis de interesse – algo que a ES se propõe a sanar. Essa medida é definida como a expectativa de perda dado que essa seja maior que o VaR (CHRISTOFFERSEN, 2012).

A partir das expectativas de perda do PIB em função dos efeitos do aquecimento global de outros estudos, Dietz et. al. (2016) calcularam o VaR relacionado a essas previsões, associando um risco financeiro global à crise climática. Já outros estudos se debruçaram sobre os riscos monetários da transição para uma produção sustentável, cunhando o conceito de Risco de Transição às possíveis perdas de valor relacionadas aos investimentos necessários para o uso de energias totalmente renováveis (SEMIENIUK et. al., 2020). Tais estudos nos indicam que a mensuração de riscos financeiros em relação às mudanças climáticas está também mergulhada em um campo de disputas econômicas e políticas, no qual os mercados de créditos de carbono foram inseridos especialmente para resolver – ao cumprir seu papel de precificar as certificações conforme a resultante de todas essas forças de mercado.

Outra evidência da íntima relação desses mercados com os riscos ambientais – bem como a tradução desses riscos na forma financeira – é sensibilidade relevante de seus preços em relação aos acordos internacionais, declarações oficiais, medidas políticas e mesmo às flutuações de temperatura (MONASTEROLO; ANGELIS, 2020). Tal volatilidade promove incertezas e dificuldades de previsão dos preços nesses mercados (JIAO; LIAO; ZHOU,

2018), mostrando que os riscos dentro dos sistemas de comércio estão ligados de forma determinante ao manejo dos riscos mais abstratos e em maior escala das mudanças ambientais. Dessa forma, ao olharmos para os riscos de mercado dos sistemas de carbono, estamos também lidando com a resultante do reflexo de diversos riscos por trás dessas trocas financeiras.

2.2.1 RISCO DE MERCADO NOS SISTEMAS DE COMÉRCIO DE CARBONO

Para além de um acúmulo de riscos externos, entretanto, os mercados de carbono têm ainda seus próprios riscos internos associados. Wang e Wang (2016) explanam ao menos oito tipos de risco a que esses sistemas estão sujeitos, entre eles o risco de suprimento, risco de liquidez e de assimetria de informações. Para o manejo desses riscos, os governos adotam regulamentações e diferentes *designs* de sistemas na tentativa de torná-los mais confiáveis e seguros para todos os atores envolvidos (WANG; WANG, 2016). Feng, Wei e Wang (2012), por exemplo, trazem que tanto o risco de queda quanto o de aumento nos preços precisam ser controlados para a boa eficiência das trocas de créditos, ao contrário de outros mercados financeiros.

A noção de que as mecânicas e *designs* de sistemas criados pelas instituições têm um impacto decisivo na capacidade desses mercados de ter um efeito real na crise climática (SHENG et. al., 2021) levou muitos pesquisadores a se debruçarem sobre a questão do risco de mercado, uma vez que os riscos são um dos principais fatores a serem observados ao se buscar a consolidação desses sistemas. Muitos desses estudos utilizam o VaR para mensuração de risco, normalmente combinado com um modelo GARCH. Dutta et. al. (2020) usaram um modelo GARCH simétrico e outros dois assimétricos com essa medida de risco para investigar o efeito de quebras estruturais na variância condicional dos preços de licenças de emissão de carbono. De fato, Paoletta e Taschini (2008) mostraram que os modelos GARCH produzem previsões acuradas do VaR para esses mercados.

Seguindo no estudo do uso de modelos da família GARCH, Chevallier (2011) investigou a existência de *outliers* na volatilidade dos preços dos créditos, destacando como conclusão que eventos anuais de conformidade em relação aos acordos e incertezas internacionais pós-Kyoto poderiam explicar a alta instabilidade dos preços. Benz e Trück (2009) analisaram o comportamento dos preços à vista das certificações no curto prazo com esses modelos. Já

Byung e Cho (2013) investigaram a volatilidade de carbonos futuros com modelos tipo GARCH usando a volatilidade de diferentes mercados do setor de energia, aos quais os preços dos créditos estão associados.

Mi e Zhang (2011), ainda, encontraram que a Teoria do Valor Extremo (EVT) também pode ser usada para estimar VaR no contexto dos mercados de crédito. Feng, Wei e Wang (2012) ainda utilizaram EVT para fazer estimativas na mesma medida de risco e um modelo GARCH para calcular VaR dinâmico. Outros estudos ainda mensuraram VaR através de diferentes métodos, como a abordagem econômica dependente do estado (JIAO; LIAO; ZHOU, 2018) e *Empirical Mode Decomposition* (ZHU et. al., 2019). Esses últimos mensuraram VaR dinâmico e encontraram que tal metodologia era capaz de reduzir as influências de ambientes heterogêneos a que, conforme já vimos, os créditos estão expostos por serem sensíveis a eventos extremos. Ainda nessa linha, Jingjing e Bin (2015) investigaram os preços à vista nos sistemas de carbono com modelos GARCH-EVT-VaR e encontraram que modelos GARCH subestimariam os riscos de choques maiores para esses dados, enquanto o GARCH-EVT tem maior capacidade de levá-los em consideração.

Apesar de a maioria dos estudos utilizarem VaR para medir risco nesses mercados, existem algumas críticas importantes a essa variável. De fato, Yang et. al. (2022) enfatizam que modelos preditivos com VaR não são capazes de descrever as distribuições de cauda assimétrica dos preços de carbono. Esses autores propõem o uso de modelos mais complexos para a utilização de VaR, já que é visto que frequentemente as distribuições dos preços de carbono nos mercados chineses possuem caudas pesadas e assimétricas (YANG et. al., 2022). Além disso, segundo o proposto por Artzner et. al. (1999), o VaR não é uma medida de risco coerente, já que não apresenta uma das quatro propriedades necessárias para tal, a saber, a de subaditividade (RIGHI; CERATTA, 2015).

Dessa forma, uma medida alternativa ao VaR é a já citada ES, já que essa é considerada uma forma coerente de mensuração dos riscos e é capaz de complementar a primeira, uma vez que essa apresenta “maior sensibilidade ao formato da cauda da distribuição dos retornos” (MORAES, 2012, p.28). Assim, tendo em vista as frequentes distribuições com caudas pesadas, parece uma boa alternativa para os dados de mercados de créditos a utilização de ambas medidas em conjunto. Fang e Cao (2021) modelaram os riscos extremos dos preços das certificações com o uso de um método semi-paramétrico e estimaram VaR e ES variantes no tempo para os mercados europeu e chineses.

Finalmente, conforme discutido por Garcia-Jorcano e Novales (2021), a distribuição de probabilidade considerada para as inovações desempenham um papel de maior peso na performance da previsão de risco que os modelos utilizados. Temos, assim, uma lacuna nos estudos sobre o risco de mercados de carbono no que se refere à análise do impacto de diferentes distribuições na sua medida e previsão, em contraste com a ampla literatura sobre as variações de modelos.

Dessa forma, segundo Gössling (2021), o VaR, para um dado nível de significância α entre 0 e 1, pode ser definido matematicamente como

$$\text{VaR}^\alpha(X) = -F_X^{-1}(\alpha),$$

em que F_X^{-1} é a função de distribuição acumulada inversa de X . Fica evidente na definição o fato de o VaR não considerar informações para além do quantil de interesse, papel cumprido pela ES que, a partir de Daniélsson (2011), pode ser definida por

$$\text{ES}^\alpha(X) = -E[X|X \leq -\text{VaR}^\alpha(X)],$$

que é exatamente o valor esperado das perdas, dado que essas ultrapassem o quantil de interesse, ou seja, o $\text{VaR}^\alpha(X)$.

3. PROCEDIMENTOS METODOLÓGICOS

Os dados utilizados nessa análise foram os do Sistema Europeu de Comércio de Emissões, o EU-ETS, que é o mais antigo e importante em termos de volume de negociações e participação no mercado global. O período escolhido para previsão corresponde majoritariamente à terceira fase do sistema, que ocorreu de primeiro de janeiro de 2013 a 31 de dezembro de 2020. Ao longo dessa fase, os preços passaram por momentos de turbulência – como por exemplo a recessão do COVID-19 – e períodos de estabilidade. Para a análise foram considerados os preços de fechamento diários de todos os dias de funcionamento do sistema. Com o uso da linguagem de programação R (R Core Team, 2021) como ferramenta, foram computados os retornos logarítmicos da série, por esses conterem propriedades estatísticas desejáveis. Na sequência, foram calculadas as estatísticas descritivas dos retornos.

Para a mensuração das variáveis de risco, foi empregado o modelo de Médias Móveis Autorregressivas (*Autorregressive Moving Average*) ARMA-GARCH, e foram consideradas as distribuições Normal, Normal Assimétrica, *t* Student, *t* Student Assimétrica, Generalizada do Erro, Generalizada do Erro Assimétrica, SU de Johnson e Emprírica. Righi e Ceratta (2015), Degiannakis e Potamia (2017) e Díaz, García-Donato e Mora-Valencia (2017) utilizam algumas dessas distribuições para previsão de risco. Segundo Gössling (2021), dado um retorno X_t observado no tempo t , e sendo z_t um processo de ruído branco com distribuição acumulada dada por F_X , o modelo ARMA(p, n)-GARCH(q, s) pode ser definido por

$$X_t = \phi_0 + \sum_{i=1}^p \phi_i X_{t-i} + \sum_{j=1}^n \theta_j \varepsilon_{t-j} + \varepsilon_t;$$
$$\varepsilon_t = \sigma_t z_t, z_t \sim i.i.d.F(0,1);$$
$$\sigma_t^2 = \omega + \sum_{j=1}^q a_j \varepsilon_{t-j}^2 + \sum_{k=1}^s b_k \sigma_{t-k}^2,$$

em que, σ_t^2 é a variância condicional no tempo t , enquanto ϕ_0 e ϕ_i , com $i = 1, \dots, p$, e θ_j com $j = 1, \dots, n$, – com p e n sendo a ordem do modelo ARMA – são os parâmetros do modelo ARMA. Ao mesmo tempo, ω ; a_j , com $j = 1, \dots, q$; e b_k , com $k = 1, \dots, s$ (sendo q e s a ordem do modelo GARCH) são os parâmetros desse modelo. Além disso, $\omega > 0$, $a_j \geq 0$ e $b_k \geq 0$.

Conforme já descrito, as medidas utilizadas nesse estudo são o VaR e a ES, recomendadas pelo Comitê da Basileia como medidas para quantificar o risco de mercado das instituições bancárias (*Basel Committee on Banking Supervision*, 2013). Além disso, tendo em vista as caudas grossas observadas em estudos anteriores (por exemplo, YANG et. al., 2022), se justifica para essa análise o uso de ES para integrar esse risco nas medidas, para além do VaR. Os quantis escolhidos são 1% e 5%, por figurarem entre os níveis mais comuns utilizados na literatura de previsão de risco.

As previsões foram computadas com método de janelas móveis rolantes, empregando um determinado número de observações para prever um passo à frente. As janelas de estimação utilizadas foram de 250 e 1000 observações. Assim, a primeira amostra foi de 2 de janeiro de 2013 a 15 de abril de 2021, em um total de 2137 observações; a segunda começou em 3 de março de 2010 e termina na mesma data que a anterior, em um total de 2887 observações utilizadas. Ambas amostras forneceram previsões para o período de 18 de dezembro de 2013 a 14 de abril de 2021, totalizando 1886 dias previstos.

As estatísticas descritivas das previsões foram computadas para cada medida de risco, nível de significância, janela de estimação e distribuição empregada no modelo. Os resultados das previsões foram avaliados a partir da Perda Realizada (\mathcal{L}_ρ), que para VaR e ES pode ser calculada, segundo Müller (2019), como

$$\mathcal{L}_{VaR^\alpha}(X, x) = E[\alpha(X - x)^+ + (1 - \alpha)(X - x)^-];$$

$$\mathcal{L}_{ES^\alpha}(X, x, z) = E[(1 - \alpha)z - IX + e^x \times (x - z + \frac{1}{\alpha}(z - X)) - e^x + 1 - \log(1 - \alpha)],$$

onde $x = -\rho$, z é uma determinada previsão obtida usando VaR, sendo $z = -VaR^\alpha$, I é uma função indicadora que assume valor igual a 1 se $X < z$, e 0 de outra forma, e $E[X]$ corresponde à definição

$$E[X] = \frac{1}{T} \sum_{t=1}^T X_t.$$

Assim, as distribuições que apresentarem valor da Perda Realizada mais próximo a zero serão as distribuições que consideramos como mais adequadas para realizar a previsão do VaR e da ES.

4. RESULTADOS

Conforme os métodos citados, foram obtidas previsões do VaR e da ES para os níveis de significância de 1% e 5%, com janelas de estimação de 250 e 1000 observações. Nas Tabelas 1 e 2 constam as médias e os desvios-padrão das previsões um passo à frente com janela de previsão rolante de 250 observações para cada medida e α , considerando as distribuições empregadas no estudo. Desses resultados, é possível perceber que os valores das estatísticas da ES são mais altos que as do VaR; isso se deve à própria definição da medida, que é utilizada para computar os valores esperados das perdas dado que essas ultrapassem o VaR. Da mesma forma, um nível de significância de 1% produzirá também valores maiores por definição, uma vez que um nível menor tem maior proteção e, conseqüentemente, uma estimativa de risco mais alta.

Tabela 1 - Estatísticas Descritivas das previsões do VaR com janela móvel de 250.

Previsões do VaR - 250 observações			
Distribuições	α	Média	desvio-padrão
Retornos reais	-	0,1172	2,8369
Normal	1%	6,1237	2,3847
	5%	4,2860	1,7052
Normal assimétrica	1%	6,0657	2,3714
	5%	4,2542	1,6912
t de student	1%	7,0356	2,8055
	5%	4,1798	1,5805
t de student assimétrica	1%	6,8296	2,7260
	5%	4,0910	1,5258
Generalizado do erro	1%	7,0216	2,8593
	5%	4,3896	1,7235
Generalizado do erro assimétrica	1%	6,8276	2,7967
	5%	4,2842	1,6638
SU de Johnson	1%	6,8984	2,7389
	5%	4,1580	1,5502
Empírica	1%	8,2192	3,8659
	5%	4,4282	1,5039

Nas previsões feitas com 250 observações, verifica-se que a distribuição Normal Assimétrica obteve as menores médias e desvios-padrão para VaR e ES com α igual a 1%, e também para α de 5% na ES. A distribuição Empírica mostra uma tendência a maiores médias e desvios-padrão em ambas medidas, apesar de apresentar menor desvio-padrão com α de 5% – nesse caso os maiores desvios foram encontrados na distribuição Generalizada do Erro. No caso do VaR, as distribuições t de Student Assimétrica, Generalizada do Erro Assimétrico e SU de Johnson obtiveram valores bastante próximos para as estatísticas com ambos níveis de significância. Já para ES obtivemos resultados semelhantes para as distribuições SU de Johnson, Generalizada do Erro e Generalizada do Erro Assimétrico, bem como as distribuições Normal e t de Student também obtiveram resultados próximos às distribuições Normal Assimétrica e t de Student Assimétrica.

Tabela 2 - Estatísticas Descritivas das previsões da ES com janela móvel de 250.

Previsões da ES - 250 observações			
Distribuições	α	Média	desvio-padrão
Normal	1%	7,0374	2,7241
	5%	5,4128	2,1212
Normal Assimétrica	1%	6,9660	2,7128
	5%	5,3649	2,1072
t de Student	1%	9,4358	4,3621
	5%	6,0499	2,4123
t de Student Assimétrica	1%	9,1284	4,2513
	5%	5,8841	2,3412
Generalizada do Erro	1%	8,5492	3,6188
	5%	6,0173	2,4216
Generalizada do Erro Assimétrica	1%	8,3057	3,5603
	5%	5,8573	2,3599
SU de Johnson	1%	8,8980	3,8680
	5%	5,9030	2,3085
Empírica	1%	13,6914	4,9354
	5%	8,0455	2,1608

Nas Tabelas 3 e 4 constam as estatísticas descritivas das previsões para as duas medidas e ambos níveis de significância computadas com janela de estimação rolante de 1000

observações. Nessa nova janela, os resultados tiveram média levemente maior e também maior amplitude se comparados com a janela mais curta de 250 observações. Mesmo assim, as distribuições com menores e maiores estatísticas foram similares às da primeira previsão: para o VaR, os menores resultados para a média estão ainda nas distribuições Normal Assimétrica e *t* de Student Assimétrica, com a diferença que os menores desvios-padrão foram encontrados em ambos níveis de significância pela *t* de Student. Já na ES, a distribuição Normal Assimétrica ainda encontrou a maior parte dos menores valores, com exceção do desvio-padrão para o α de 5%, que figurou na distribuição *t* de Student. Para as duas medidas, a distribuição Empírica ainda elencou os maiores resultados, novamente com a exceção do desvio-padrão para α igual a 5%, que nesse caso foi obtida pela distribuição SU de Johnson.

Tabela 3 - Estatísticas Descritivas das previsões do VaR com janela móvel de 1000 observações

Previsões do VaR - 1000 observações			
Distribuições	α	Média	desvio-padrão
Retornos reais	-	0,1172	2,8369
Normal	1%	7,0226	2,9819
	5%	4,9368	2,1549
Normal Assimétrica	1%	6,9389	2,9712
	5%	4,8876	2,1472
t de Student	1%	7,9345	2,9187
	5%	4,3226	1,4935
t de Student Assimétrica	1%	7,9287	3,2785
	5%	4,3136	1,5576
Generalizada do Erro	1%	8,6240	3,9802
	5%	4,8788	1,8230
Generalizada do Erro Assimétrica	1%	8,4126	3,8054
	5%	4,7771	1,7666
SU de Johnson	1%	11,7606	11,8191
	5%	5,2201	3,0682
Empírica	1%	17,5607	12,5246
	5%	5,6578	1,6221

Tabela 4 - Estatísticas Descritivas das previsões do VaR com janela móvel de 1000 observações

Previsões da ES - 1000 observações			
Distribuições	α	Média	desvio-padrão
Normal	1%	8,0597	3,3957
	5%	6,2157	2,6609
Normal assimétrica	1%	7,9582	3,3837
	5%	6,1453	2,6514
<i>t</i> de Student	1%	11,9200	5,4630
	5%	6,8340	2,5182
<i>t</i> de Student Assimétrica	1%	12,0080	6,5162
	5%	6,8420	2,8550
Generalizada do Erro	1%	11,1562	5,9240
	5%	7,2287	3,1820
Generalizada do Erro Assimétrica	1%	10,8663	5,6349
	5%	7,0577	3,0473
SU de Johnson	1%	20,7933	28,9573
	5%	10,0211	10,1988
Empírica	1%	29,1888	10,0105
	5%	15,1871	4,5972

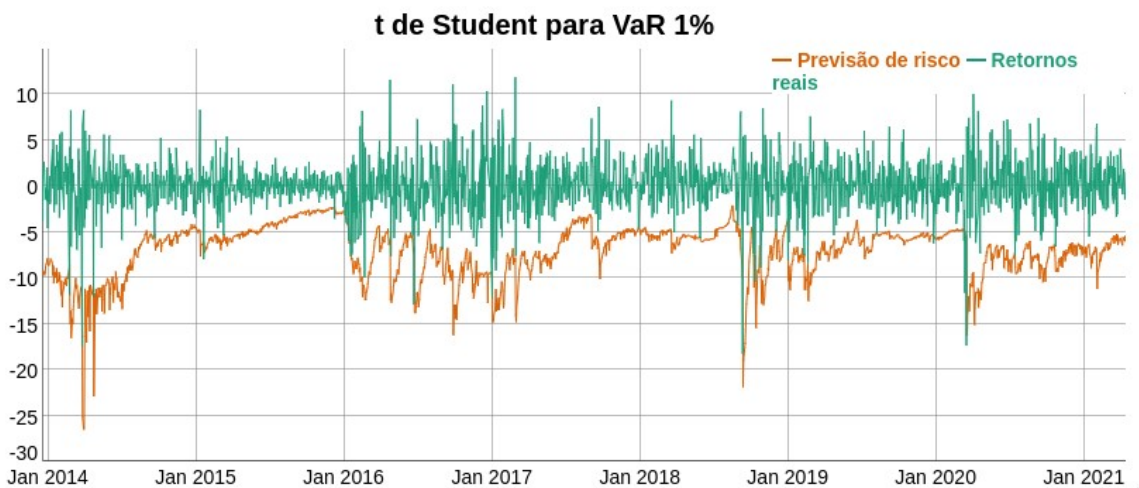
Os resultados da Perda Realizada para cada medida de risco, nível de significância e distribuição estão dispostos nas Tabelas 5 e 6. Para as previsões com janela de 250 observações (Tabela 5), vemos que a distribuição *t* de Student obteve as menores Perdas Realizadas considerando um α de 1%, tanto para VaR quanto para ES. Essa distribuição se adapta bem a dados financeiros por ter caudas mais largas que a distribuição Normal e ser, portanto, capaz de modelar a curtose, que observamos ter um valor alto na amostra, de 11,517. Dessa forma, nossos resultados estão em consonância com os resultados de Angelidis, Benos e Degiannakis (2004), que encontraram estimações de risco mais acuradas para índices de mercado utilizando distribuições leptocúrticas; de fato, vários estudos obtiveram melhores resultados de previsão de risco com a distribuição *t* de Student Assimétrica (KUESTER; MITTNIK; PAOLELLA, 2006; MABROUK; SAADI, 2012; ZHOU, 2012). As previsões

para o VaR com a distribuição t de Student a nível 1% com janela de estimação de 250, bem como os retornos logarítmicos, estão ilustradas na Figura 1. Por meio da análise da figura, pode-se verificar que as previsões de risco acompanham a dinâmica da série. Também é possível notar que os períodos de maior variabilidade são capturados pela distribuição que consideramos para modelar os dados.

Tabela 5 - Perda Realizada para cada medida de risco e α das previsões com janela móvel de 250 observações

Perda Realizada das previsões - 250 observações				
Distribuições	VaR 1%	VaR 5%	ES 1%	ES 5%
Normal	11,1671	14,2661	114,4880	136,9077
Normal Assimétrica	11,3098	14,4245	<i>114,7198</i>	136,8862
t de Student	10,3489	14,5985	111,6771	136,0841
t de Student Assimétrica	10,5701	14,8865	112,1389	136,0548
Generalizada do Erro	10,3521	13,8751	111,9407	136,2105
Generalizada do Erro Assimétrica	10,6275	14,2461	112,3512	136,1633
SU de Johnson	10,5676	14,6031	112,1368	135,9852
Empírica	<i>12,0543</i>	<i>16,2076</i>	112,9999	<i>138,9849</i>

Nota: valores multiplicados por 100. Os números em negrito destacam os melhores resultados, enquanto os números em itálico se referem aos piores.



Fonte: a autora

Figura 1: Previsão do VaR com distribuição t de Student, α de 1% e janela de estimação de 250 observações.

Já as menores Perdas Realizadas para o VaR de α 5% foram obtidas pela distribuição Generalizada do Erro nos dois tamanhos amostrais, enquanto que, para a ES 5%, essas foram produzidas pela distribuição SU de Johnson na menor amostra e pela t de Student nas previsões com janela de tamanho 1000 (Tabela 6). Novamente, podemos atribuir esse desempenho ao fato de essas distribuições possuírem parâmetro de curtose, que permite modelar as caudas pesadas usualmente presentes em dados financeiros. Podemos também perceber que distribuições que apresentam parâmetros de assimetria, como o caso da t de Student Assimétrica, não apresentaram os melhores resultados. Essa conclusão difere dos resultados da literatura, conforme referido. Uma justificativa para isso é que os retornos de créditos de carbono apresentam uma assimetria negativa, mas com um valor próximo de zero.


Tabela 6 – Perda Realizada para cada medida de risco e α das previsões com janela móvel de 1000 observações

Perda Realizada das previsões - 1000 observações				
Distribuições	VaR 1%	VaR 5%	ES 1%	ES 5%
Normal	10,3458	12,9536	112,1974	137,3261
Normal assimétrica	10,4411	13,0949	112,5792	137,3953
t de Student	10,3551	13,9730	111,1635	135,7775
t de Student assimétrica	10,5307	<i>14,2075</i>	111,3447	135,9465
Generalizada do Erro	10,4631	12,3346	111,2365	136,2747
Generalizada do Erro Assimétrica	10,4402	12,5784	111,2283	136,1190
SU de Johnson	13,9249	13,1359	114,7395	138,5252
Empírica	<i>19,2934</i>	13,3672	<i>120,1812</i>	<i>141,0063</i>

Nota: valores multiplicados por 100. Os números em negrito destacam os melhores resultados, enquanto os números em itálico se referem aos piores.

Por outro lado, a distribuição Normal, que nas previsões com amostra de 250 observações está entre as de pior desempenho, excepcionalmente teve a menor Perda Realizada para VaR com nível de significância igual a 1% nas previsões com maior amostra, ou seja, 1000 observações. Há evidências de que dados financeiros usualmente diferem da distribuição Normal, tendo essa sido considerada insuficiente para a modelagem dessas amostras (MÜLLER; RIGHI, 2018). Portanto, a performance ruim era esperada, uma vez que estudos anteriores já encontraram que a Normal não gera previsões um passo à frente acuradas para VaR (ANGELIDIS; BENOS; DEGIANNAKIS, 2004). Também podemos ver na Tabela 4 que a Perda Realizada para o VaR 1%, obtido pela distribuição Normal,

apresentou resultado próximo a estimativa obtida considerando a distribuição t de Student. As previsões de VaR 1% com distribuição Normal e janela de estimação de 1000 observações estão ilustradas na Figura 2.



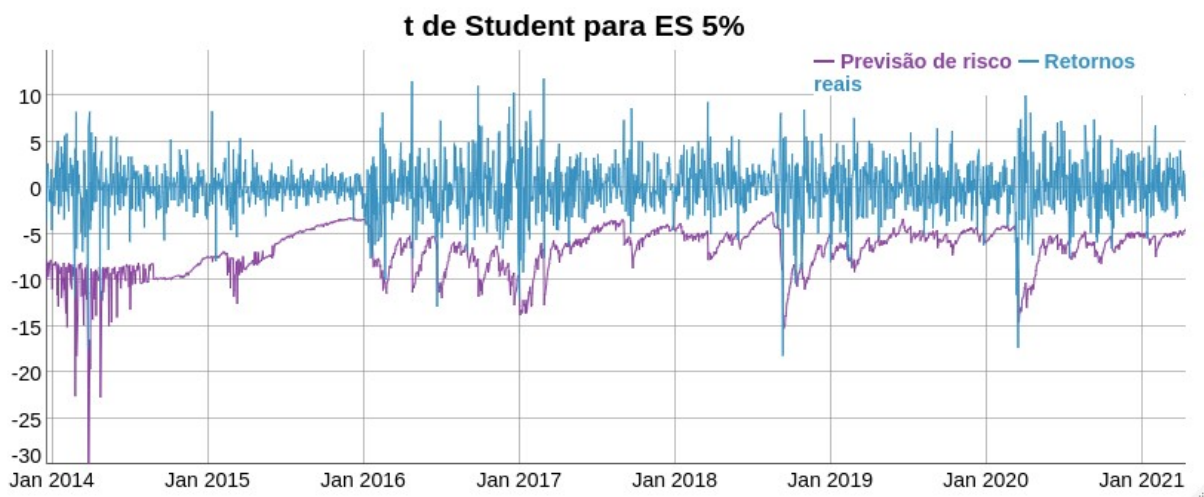
Fonte: a autora

Figura 2 - Previsão do VaR com distribuição Normal, α de 1% e janela de estimação de 1000 observações.

Os piores resultados, que estabeleceram as maiores Perdas Realizadas, foram obtidos pela distribuição Empírica. Segundo Müller e Righi (2018), as previsões geradas com a distribuição Empírica demoram a responder à volatilidade e a grandes variações no preço, produzindo estimativas ruins tanto para VaR quanto para ES. O método de Simulação Histórica, que foi usada do caso da distribuição Empírica, tende a superestimar o risco em períodos estáveis e tende a subestimar o risco em períodos de volatilidade (MÜLLER; RIGHI, 2018). Esse comportamento gera a tendência à previsões de risco menos acuradas, apesar de essa técnica ser comum para previsões de risco na prática. Esse efeito parece ter sido ainda maior no caso da amostra de 1000 observações. Além da distribuição Empírica, a distribuição SU de Johnson também teve pior desempenho para três das quatro combinações de medida e α na amostra de 1000 observações, sugerindo que essa distribuição não deve ser considerada para realizar a previsão dos retornos de créditos de carbono.

Apesar disso, pode-se notar que não houve uma diferença marcante na Perda Realizada para as demais distribuições em relação às duas janelas de estimação quando comparadas. Ao olhar da perspectiva das medidas para cada nível de significância, no entanto, percebemos que a janela maior forneceu menores valores para a Perda Realizada no VaR 5% e, dentre os

números obtidos pelas distribuições com melhor desempenho, também forneceu menores perdas para a ES em ambos α . Esses resultados corroboram com Righi e Ceratta (2015), que encontraram piores estimativas para a ES com janelas menores, avaliando que informações relevantes podem ficar de fora da amostra ao utilizá-las. A Figura 3 ilustra a previsão de risco da ES com α de 5% obtidos com a distribuição t de Student e com amostra de 1000 observações.



Fonte: a autora

Figura 3 - Previsão da ES com distribuição t de Student, α de 5% e janela de estimação de 1000 observações.

Diante do que foi abordado, podemos perceber que as distribuições que melhor modelaram os retornos dos créditos de carbono foram as simétricas e com parâmetro de curtose, segundo o critério da Perda Realizada. Portanto, as mais recomendadas para utilização nas previsões de risco são a t de Student e Generalizada do Erro, já que essas modelam as caudas pesadas presentes nesses dados, tal como descrito anteriormente por Yang et. al. (2022). O uso das distribuições Empírica e Normal não é recomendado. A janela de estimação rolante de 1000 observações forneceu, no geral, menores Perdas Realizadas que a janela de 250 observações. Esses resultados são úteis para maior precisão da previsão de risco no mercado de créditos de carbono europeu e para estudos subsequentes de risco nesses mercados.

5. CONCLUSÃO

O objetivo desse estudo foi o de analisar o uso de diferentes distribuições de probabilidade na modelagem das previsões de duas medidas de risco, VaR e ES, e encontrar quais fornecem melhores resultados. Para a avaliação das previsões de risco foi utilizada a Perda Realizada. Conforme já descrito na literatura, as distribuições leptocúrticas obtiveram melhor desempenho, com destaque para a t de Student e a Generalizada do Erro. Ambas distribuições permitem modelar as caudas pesadas observadas em dados financeiros, que também estão presentes na amostra de dados investigada. Um resultado interessante foi a pior performance das distribuições assimétricas, o que é possivelmente explicado pela maior regulamentação dos mercados de carbono em relação a mercados de outros ativos financeiros, o que pode levar a maior simetria dos preços no curto prazo.

Já as piores estimações foram obtidas pelas distribuições Empírica e Normal, que corrobora com resultados da literatura observados para outras classes de ativos. As previsões com a distribuição Normal tiveram maiores Perdas Realizadas na janela de estimação rolante de 250 observações. Entretanto, a Normal teve desempenho melhor nas estimações com tamanho amostral de 1000, sendo inclusive a mais acurada estimação para VaR com nível de significância de 1%. Além da Normal, a distribuição SU de Johnson foi a que teve maior diferença na Perda Realizada ao se considerar os dois tamanhos amostrais, obtendo menor perda nas previsões feitas com a menor janela. De forma geral, entre as distribuições que obtiveram melhor desempenho, a maior janela de estimação rolante forneceu menores Perdas Realizadas que a janela de 250 observações.

Diante desses números, estimações de risco com dados de mercado de créditos de carbono podem utilizar as distribuições de melhor desempenho para computar previsões, o que contribui diretamente para a gestão de risco das organizações. Uma das implicações de incorporar os custos de emissões na produção é adicionar mais um fator de risco aos que impactam a rentabilidade das empresas. Nesse sentido, apesar de serem uma tentativa de otimização dos preços associados à produção de gás carbônico, os mercados trazem maior complexidade ao cálculo de custos e à sua previsibilidade. É dessa forma que a previsão de riscos nos sistemas de comércio de carbono podem trazer uma contribuição central para a organização financeira de empresas e projetos no que diz respeito a decisões tanto de nível operacional, como previsão de custos e planejamento de caixa, quanto de nível estratégico,

como investimentos de longo prazo e estruturas de produção – podendo afetar ainda, no limite, o próprio modelo de negócios dessas organizações.

Uma boa gestão de risco já está tradicionalmente associada a melhores performances das empresas, por levar a fluxos de caixa menos voláteis, resultando em menores custos de capital e mais investimentos (CHRISTOFFERSEN, 2012). Mesmo antes de as *commodities* de carbono serem trazidas à realidade industrial, o curso das políticas ambientais já tornavam empresas que tivessem um manejo de qualidade em relação às mudanças climáticas menos propensas a riscos e mais capazes de crescimento (BUSH; HOFFMANN, 2006). Hoje, as emissões de carbono não apenas impactam o valor de mercado das organizações, como também estão associadas a maiores riscos de inadimplência da parte dessas, justamente porque as expõem a maiores riscos ambientais – que são traduzidos em maiores custos das dívidas (KABIR et. al., 2021). De fato, era previsto que investidores, consumidores, instituições financeiras e a sociedade em geral se tornassem mais atentos aos riscos ambientais e ajustassem suas decisões em torno dessa consciência (BUSH; HOFFMANN, 2006).

Embora os riscos ligados ao carbono não estejam distribuídos homoganeamente entre os diversos setores econômicos, os maiores produtores de emissões são atores centrais na indústria, como energia e combustíveis (BUSH; HOFFMANN, 2006), o que gera um efeito indireto para toda a economia. Uma vez que essas empresas enfrentam desafios de performance pelos custos adicionais de conformidade legal, maiores custos de capital, maiores instabilidades de fluxo de caixa, entre outros (KABIR et. al., 2021), se faz imprescindível a gestão de riscos de carbono para a melhor eficiência dessas individualmente e, em termos amplos, de todo o mercado. Jung, Herbohn e Clarkson (2016) explicitam que tais efeitos financeiros negativos podem ser remediados com a consciência de risco de carbono – isto é, medidas de transparência e manejo de risco –, o que mostra que os diversos *stakeholders* são sensíveis à forma como as empresas lidam com os riscos ambientais em sua produção.

Esse estudo, portanto, colabora com a investigação a respeito dos riscos no mercado de carbono, conhecimento que promove maiores chances para a gestão adequada e informações mais acuradas para a tomada de decisão e alocação de recursos em organizações que emitem GEE. Pode, ainda, ter contribuído de maneira útil para a construção de estratégias de gestão de risco tão necessárias para a continuidade e o bom funcionamento desses sistemas, cada vez

mais amplamente empregados na mitigação da mudança climática. Trabalhos subsequentes nesse âmbito podem ainda partir desses resultados para seguir o estudo da modelagem de risco e seu impacto no comércio de compensações de carbono.

REFERÊNCIAS

- ANGELIDIS, Timotheos; BENOS, Alexandros; DEGIANNAKIS, Stavros. The Use of GARCH Models in VaR Estimation. **Statistical methodology**, v. 1, n. 1, p. 105–128, 2004.
- ARTZNER, Philippe; DELBAEN, Freddy; EBER, Jean-Marc; HEATH, David. Coherent Measures of Risk. **Mathematical Finance**, v. 9, n. 3, p. 203-228, 1999.
- BENZ, Eva; TRÜCK, Stefan. Modeling the price dynamics of CO2 emission allowances. **Energy Economics**, v. 31, p. 4-15, 2009.
- BASEL Committee on Banking Supervision. Fundamental review of the trading book: A revised market risk framework. **Documento para consulta**, 2013.
- BRYANT, Gareth. **Carbon Markets in a Climate-Changing Capitalism**. Cambridge University Press, 2019.
- BUSH, Timo; HOFFMANN, Volker H. Emerging Carbon Constraints for Corporate Risk Management. **Ecological Economics**, v. 62, p. 518-528, 2006.
- BYUN, Suk J.; CHO, Hangjun. Forecasting carbon futures volatility using GARCH models with energy volatilities. **Energy Economics**, v. 40, 207-221, 2013.
- CALEL, Raphael. Carbon markets: a historical overview. **WIREs Climate Change**, v. 4, p. 107-119, 2013.
- CHEVALLIER, Julien. Detecting instability in the volatility of carbon prices. **Energy Economics**, v. 33, p. 99-110, 2011.
- CHRISTOFFERSEN, Peter. **Elements of Financial Risk Management**. Elsevier, 2012.
- CONTE, Marc N.; KOTCHEN, Matthew J. Explaining the price of voluntary carbon offsets. **Climate Change Economics**, v. 1, n. 2, p. 93-111, 2010.
- CRAMTON, Peter C.; MACKAY, David J. C.; OCKENFELS, Axel (ed). **Global carbon pricing: the path to climate cooperation**. Massachusetts Institute of Technology, 2017.
- DANÍELSSON, Jón. **Financial Risk Forecasting: The Theory and Practice of Forecasting Market Risk, with Implementation in R and Matlab**. Willey Finance, 1ª ed., 2011.
- DEGIANNAKIS, Stavros; POTAMIA, Artemis. Multiple-days-ahead value-at-risk and expected shortfall forecasting for stock indices, commodities and exchange rates: inter-day versus intra-day data. **International Review of Financial Analysis**, nº 49, p. 176-190, 2017.
- DÍAZ, Antonio; GARCÍA-DONATO, Gonçalo; MORA-VALENCIA, Andrés. Risk quantification in turmoil markets. **Risk Management**, v. 19, p. 202-224, 2017.

- DIETZ, Simon; BOWEN, Alex; DIXON, Charlie; GRADWELL, Philip. 'Climate value at risk' of global financial assets. **Nature Climate Change**, v. 6, p. 676-680, 2016.
- DUTTA, Anupam; JALKH, Naji; BOURI, Elie; DUTTA, Probal. Assessing the risk of the European Union carbon allowance market: Structural breaks and forecasting performance. **International Journal of Managerial Finance**, v. 16, n° 1, p. 49-60, 2020.
- FANG, Sheng; CAO, Guangxi. Modelling extreme risk for carbon emission allowances: Evidence from European and Chinese carbon markets. **Journal of Cleaner Production**, v. 316, 2021.
- FENG, Zhen-Hua; WEI, Yi-Ming; WANG, Kai. Estimating Risk for the Carbon Market via Extreme Value Theory: An Empirical Analysis of the EU ETS. **Applied Energy**, v. 99, p. 97-108, nov. 2012.
- FENG, Zhen-Hua; ZOU, Le-Le; WEI, Ming-Yi. Carbon price volatility: Evidence from EU ETS. **Applied Energy**, v. 88, p. 590-598, 2011
- GARCIA-JORCANO, Laura; NOVALES, Alfonso. Volatility specifications versus probability distributions in VaR forecasting. **Journal of Forecasting**, v. 40, p. 189-212, 2021.
- GÖSSLING, Thalles W. **A comparison of Range Value at Risk forecasting models**. Dissertação (Mestrado em Administração) – Escola de Administração da UFRGS. Porto Alegre, 2021.
- ICAP. Emissions Trading Worldwide: status report 2021. **International Carbon Action Partnership**. Berlin, 2021.
- IHS MARKIT. A Global Price for Carbon Emissions. **Climate Finance Partners**, abr. 2020.
- JIAO, Lei; LIAO, Yin; ZHOU, Qing. Predicting carbon market risk using information from macroeconomic fundamentals. **Energy Economics**, v. 73, p. 212-227, mai. 2018.
- JINGJING, Jiang; BIN, Ye. Value-at-Risk estimation of carbon spot market based on the combined GARCH-EVT-VaR model. **Advanced Materials Research**, v. 1065-1069, p. 3250-3253, 2015.
- JUNG, Juhyun; HERBOHN, Kathleen; CLARKSON, Peter. Carbon Risk, Carbon Risk Awareness and the Cost of Debt. **Journal of Business Ethics**, n. 150, p. 1151-1171, mai. 2016.
- KABIR, Md Nurul. RAHMAN, Sohanur; RAHMAN, Md Arifur; ANWAR, Mumtaheena. Carbon Emissions and Default Risk: international evidence from firm-level data. **Economic Modelling**, v. 103, 2021.
- KAUFMAN, Noah; BARRON, Alexander R.; KRAWCZYK, Wojciech.; MASTERS, Peter; MCJEON, Haewon. A Near-term to Net Zero Alternative to the Social Cost of Carbon for Setting Carbon Prices. **Nature Climate Change**, v. 10, p. 1010-1014, nov. 2020.
- KUESTER, Keith; MITTNIK, Stefan; PAOLELLA, Marc S. Value-at-risk Prediction: A comparison of alternative strategies. **Journal of Financial Econometrics**, v. 4, n° 1, p. 53-89, 2006.

- LOHMANN, Larry. Neoliberalism and the Calculable World: The Rise of Carbon Trading. *In*: BÖHM, Steffen; DABHI, Siddhartha (org.). **Upsetting the offset: the political economy of carbon markets**. London: Mayfly, p. 25-37, 2009.
- MABROUK, Samir; SAADI, Samir. Parametric Value-at-Risk Analysis: Evidence from stock indices. **The Quarterly Review of Economics and Finance**, v. 52, n° 3, p. 305–321, 2012.
- MI, Zhi-Fu; ZHANG, Yue-Jun. Estimating the “value at risk” of EUA futures prices based on the extreme value theory. **Global Energy Issues**, v. 35, n. 2/3/4, 2011.
- MONASTEROLO, Irene; ANGELIS, Luca de. Blind to carbon risk? An analysis of stock market reaction to the Paris Agreement. **Ecological Economics**, v. 170, 2020.
- MORAES, Camila C. **Value at Risk e Expected Shortfall: Medidas de risco e suas propriedades**. Um estudo empírico para o mercado brasileiro. Dissertação (Mestrado em Economia) – Escola de Economia de São Paulo. São Paulo, 2012.
- MÜLLER, Fernanda M. **Essays on model risk for risk measures**. (Doutorado em Administração) – Escola de Administração da UFRGS. Porto Alegre, 2019.
- MÜLLER, Fernanda M.; RIGHI, Marcelo B. Numeral comparison of multivariate models to forecasting risk measures. **Risk Management**, v. 20, p.29-50, 2018.
- NEWELL, Richard G.; PIZER, William A.; RAIMI, Daniel. Carbon Markets 15 Years after Kyoto: lessons learned, new challenges. **Journal of Economic Perspectives**, v. 27, n. 1, p. 123-146, 2013.
- PAOLELLA, Marc S.; TASCHINI, Luca. An econometric analysis of emission allowance prices. **Journal of Banking & Finance**, v. 32, n° 10, p. 2022-2032, 2008.
- PATT, Anthony; LILLIESTAM, Johan. The Case Against Carbon Prices. **Joule**, v. 2, p. 2487-2510, dez. 2019.
- R Core Team. **R: A Language and Environment for Statistical Computing**. Vienna, Áustria, 2021. Disponível em: <<https://www.R-project.org/>>.
- RIGHI, Marcelo B. A composition between risk and deviation measures. **Annals of Operations Research**, v. 282, n° 1, p. 299-313, 2019.
- RIGHI, Marcelo B.; CERATTA, Paulo S. A comparison of Expected Shortfall estimation models. **Journal of Economics and Business**, v. 78, p. 14-47, 2015.
- SEMIENIUK, Gregor; CAMPIGLIO, Emanuele; MERCURE, Jean-Francois; VOLZ, Ulrich; EDWARDS, Neil R. Low Carbon Transition Risks for Finance. **WIREs Climate Change**, v. 12, n. 1, 2020.
- SHENG, Chunguang; ZHANG, Degang; WANG, Guangyu; HUANG, Yingli. Research on risk mechanism of China’s carbon financial market development from the perspective of ecological civilization. **Journal of Computational and Applied Mathematics**, v. 381, jan. 2021.

WANG, Zhaohua.; WANG, Chen. How carbon offsetting scheme impacts the duopoly output in production and abatement: analysis in the context of carbon cap-and-trade. **Journal of Cleaner Production**, v.103, p. 715-723, 2015.

WANG, Yao; WANG, Wentao. Risk identification and regulatory design for the carbon market. **Chinese Journal of Population Resources and Environment**, 2016.

WORLD BANK. State and Trends of Carbon Pricing. **World Bank**, Washington DC, 2020.

YANG, Xianzi; ZHANG, Chen; YANG, Yu; WANG, Wenjun; WAGAN, Zulfiqar A. A new risk measurement method for China's carbon market. **International Journal of Finance & Economics**, v. 27, n. 1, p. 1280-1290, 2022.

ZHOU, Jian. Extreme Risk Measures for REITs: A comparison among alternative methods. **Applied Financial Economics**, Taylor & Francis, v. 22, n. 2, p. 113–126, 2012.

ZHU, Bangzhu; YE, Shunxin; HE, Kaijian; CHEVALLIER, Julien; XIE, Rui. Measuring the risk of European carbon market: an empirical mode decomposition-based value at risk approach. **Annals of Operations Research**, v. 281, p. 373-395, 2019.