

Sumário

Capítulo 1. Breve Introdução sobre o Machine Learning

1.1. Retrospectiva

1.2. Principais Técnicas

Capítulo 2. Revisão do Uso Internacional

Capítulo 3. Revisão do Uso Nacional

Capítulo 4. Conclusões e Visão de Futuro

Capítulo 1

Breve Introdução sobre o Machine Learning

Este trabalho tem como objetivo elaborar uma revisão bibliográfica sobre o uso das ferramentas de IA na comercialização de energia elétrica no Brasil e no Mundo. Antes de serem introduzidos os conceitos básicos de uma maneira mais formal, faz-se necessário explicar de uma forma prática e objetiva sobre quais tipos de IA estarão sendo tratadas neste trabalho.

Para isso, nada melhor do que a própria IA para explicar o que é a IA. Segue abaixo uma pequena conversa entabulada com um dos vários LLMs (Large Language Models) disponíveis comercialmente.

Autores: Você poderia me explicar de forma simples o que é Inteligência Artificial? Por favor, use 200 palavras.

LLM: Inteligência Artificial (IA) é um campo da ciência da computação dedicado à criação de máquinas capazes de realizar tarefas que normalmente requerem inteligência humana. Essas tarefas incluem aprendizagem, raciocínio, resolução de problemas, percepção e compreensão da linguagem. Os sistemas de IA são projetados para imitar as funções cognitivas humanas, permitindo-lhes analisar e interpretar dados complexos, reconhecer padrões e tomar decisões.

A IA pode ser categorizada em dois tipos: IA fraca e IA forte. A IA fraca foi projetada para tarefas específicas, como tradução de idiomas ou reconhecimento de imagens, e é predominante em muitas das aplicações atuais. A IA forte, que ainda é teórica, refere-se a sistemas que possuem a inteligência e as habilidades cognitivas de um ser humano, capazes de compreender e aprender qualquer tarefa intelectual que um ser humano possa realizar.

O desenvolvimento da IA envolve diversas tecnologias, incluindo as técnicas de Machine Learning, onde os computadores aprendem a partir de dados sem serem explicitamente programados; processamento de linguagem natural, que permite às máquinas compreender e interagir utilizando a linguagem humana; e robótica, que combina IA com máquinas físicas.

O impacto da IA é generalizado, revolucionando indústrias desde a saúde até às finanças, melhorando a eficiência e permitindo novas possibilidades. No entanto, também levanta considerações éticas e sociais, como a deslocação do emprego e preocupações com a privacidade. À medida que a IA continua a avançar, a sua integração na vida quotidiana e na economia global torna-se mais significativa, tornando a sua compreensão cada vez mais importante.

Autores: Você poderia nos explicar de forma breve como a IA pode ajudar na área de comercialização de energia elétrica?

LLM: A IA pode melhorar significativamente a comercialização de eletricidade de várias maneiras:

1. Análise e previsão de mercado: algoritmos de IA podem analisar grandes quantidades de dados de diversas fontes, incluindo tendências históricas de mercado, previsões meteorológicas e padrões de consumo de energia em tempo real. Esta análise ajuda a prever com precisão os preços, a demanda e a oferta de eletricidade, permitindo aos comercializadores tomar decisões fundamentadas e capitalizar as oportunidades de mercado.

2. Gerenciamento de riscos: a IA pode identificar riscos potenciais, analisando tendências de mercado e fatores externos, como mudanças regulatórias ou eventos geopolíticos. Esta avaliação proativa de risco ajuda os traders a mitigar perdas potenciais.

3. Negociação Automatizada: A IA pode automatizar o processo de negociação, executando negociações em momentos ideais com base em critérios predefinidos ou análise de mercado em tempo real. Esta automação aumenta a eficiência e pode capitalizar as mudanças do mercado mais rapidamente do que a negociação manual.

4. Integração de Energias Renováveis: Com a crescente importância das fontes de energia renováveis, a IA pode ajudar a equilibrar a rede, prevendo a produção de energia renovável (como energia solar ou eólica) e ajustando as negociações em conformidade para garantir um fornecimento de energia estável.

5. Gerenciamento de resposta à demanda: A IA pode otimizar a comercialização de eletricidade prevendo períodos de pico de demanda e sugerindo estratégias como resposta à demanda, onde os consumidores são incentivados a reduzir ou alterar seu uso de energia durante horários de pico.

6. Contratos de energia personalizados: a IA pode analisar dados de clientes para oferecer contratos de energia personalizados, maximizando o valor para fornecedores e consumidores.

Ao aproveitar estas capacidades, a IA pode tornar a comercialização da energia elétrica mais eficiente, rentável e alinhada com o cenário energético em evolução.

Impressionante, não?

Num artigo publicado em 1950, o cientista da computação Alan Turing sugeriu um teste lendário para verificar se um programa de computador poderia ser classificado como inteligente. A ideia era a seguinte: quando esse programa conseguisse exibir capacidades de conversação semelhantes às humanas durante um longo período, de modo que um interlocutor humano não conseguisse perceber que estava falando com uma máquina, o programa seria aprovado no teste, ou seja, seria considerado inteligente [1]. Durante mais de sete décadas, este teste simples representou um tremendo desafio inspiracional para muitos pesquisadores da IA. Hoje, como pode-se inferir com os LLMs, o Teste de Turing já foi vencido.

Sem sombra de dúvida estamos começando a viver num admirável mundo novo, com ferramentas verdadeiramente inteligentes. Em 2023 vimos as Big Techs apostando tudo na IA generativa. O ano de 2023 pode ficar na história como o ano em que se viu o maior número de lançamentos de ferramentas de IA: LLaMA 2 da Meta, chatbot Bard e Gemini do Google, Ernie Bot do Baidu, GPT-4 da OpenAI. Uma das grandes novidades é que algumas empresas estão permitindo que desenvolvedores criem suas próprias aplicações e chatbots de IA personalizados, sem a necessidade de habilidades de codificação.

Já existem notícias de que algumas organizações de cunho religioso estão utilizando a IA com grande relevância no aconselhamento dos seus membros e também já existem empresas que estão vendendo serviços em que algumas famílias conseguem falar com seus entes queridos que faleceram anos atrás, através de emulação de IA [2, 3].

Embora todos estejam implementando LLMs em vários produtos e em um ritmo frenético, ainda há muito o que se avançar nessa área. Sabe-se por experiência própria que os LLMs inventam que algumas coisas e têm graves preconceitos étnicos e de gênero. Nada muito diferente dos humanos. Mas de forma geral, tem-se visto muitas pesquisas tentando entender por que essas ferramentas se comportam

dessa maneira e, em última análise, fazê-las se comportarem melhor, educando-as adequadamente. Novamente, nada muito diferente dos humanos.

Apesar desses percalços, e apesar do mundo ainda estar na infância da IA Generativa, essa etapa inicial já tem se apresentado imensamente lucrativa. Ao todo, as cerca de 100 empresas criaram juntas US\$ 8 trilhões em valor de mercado para seus proprietários, desde outubro de 2022, pouco antes do lançamento do ChatGPT, até março de 2024 [4].

Por incrível que pareça, a primeira aplicação de mundo real que a DeepMind desenvolveu foi uma IA para controlar o sistema de refrigeração de um Data Center do Google com o objetivo de reduzir o consumo de energia elétrica. Eles conseguiram uma economia de cerca de 40%. Isso em 2016. A DeepMind usou uma técnica de Machine Learning (ML), chamada Reinforcement Learning. Vê-se como o setor elétrico e a IA estão intimamente relacionados e como ambos podem se beneficiar com o compartilhamento do conhecimento [5].

Para ajudar no entendimento dessas várias famílias de técnicas de IA, a Figura 1 apresenta os principais ramos da IA e tenta esclarecer que família de técnica é um subconjunto de uma família maior e as intersecções existentes.




Figura 1. – Subconjuntos da IA.
Fonte: [6].

Para quem tiver interesse em outras aplicações da IA recomenda-se o site “State of AI Report 2023” (<https://www.stateof.ai/>). O objetivo deste Report é incentivar o compartilhamento de informações confiáveis sobre o estado da IA e suas implicações para o futuro.

1.1. – Retrospectiva

Uma breve retrospectiva dos avanços alcançados na IA é útil para compreender como as técnicas antigas e as novas ideias podem ser aproveitadas para resolver problemas de maneiras inovadoras. A compreensão dos fundamentos da IA, que datam de várias décadas, é indispensável para a melhor utilização das técnicas mais modernas de IA.

Um dos mais importantes conceitos na área da IA é o conceito de Rede Neural Artificial (RNA). Este conceito remonta às tentativas de se compreender e simular o funcionamento dos neurônios do cérebro humano usando uma abordagem computacional.

O conceito da Rede Neural Artificial teve suas raízes nas décadas de 1940 e 1950, quando neurofisiologistas começaram a ter uma compreensão mais clara da estrutura e funcionamento dos neurônios no cérebro humano. Warren McCulloch e Walter Pitts, em 1943 [7], publicaram um trabalho considerado o início das redes neurais artificiais. Neste trabalho, McCulloch e Pitts introduziram um modelo simplificado de neurônio, que eles propuseram como uma unidade básica de computação.

Em 1958, Frank Rosenblatt introduziu o conceito de Perceptron [8]. O Perceptron é um tipo de Rede Neural Artificial desenvolvida para classificar dados linearmente separáveis. Rosenblatt foi inspirado pelo trabalho de McCulloch e Pitts e procurou criar uma máquina que pudesse aprender a partir de dados. Embora os Perceptrons tenham sido um avanço significativo na época, eles tinham limitações, como a incapacidade de resolver problemas que não eram linearmente separáveis.

Em 1969, Marvin Minsky e Seymour Papert publicaram o livro "Perceptrons", que analisava em profundidade as limitações dos Perceptrons e mostrava que eles não poderiam resolver problemas simples como a função XOR [9]. Essa crítica teve um grande impacto, levando a um declínio no interesse e no financiamento para pesquisa em redes neurais. Inaugurando o chamado "1º Inverno da IA".

Na década de 1980, o interesse pelas Redes Neurais foi reavivado graças a várias descobertas e inovações. Um desenvolvimento chave foi o algoritmo de retropropagação (*backpropagation*), apresentado de forma mais completa por Rumelhart, Hinton e Williams em 1986 [10]. Este algoritmo permitiu que redes neurais com múltiplas camadas fossem treinadas de forma eficiente.

O ressurgimento atual do interesse em Redes Neurais começou na década de 2000 e explodiu na década de 2010, em grande parte devido ao crescimento do poder computacional (particularmente por causa dos chips GPUs), e dos grandes volumes de dados disponíveis para treinamento e melhorias nos algoritmos.

O termo "*Deep Learning*" começou a ser usado para descrever Redes Neurais com muitas camadas, que são capazes de aprender representações de dados em vários níveis de abstração.

Assim, a origem do conceito de Rede Neural artificial está profundamente ligada à biologia e à tentativa de simular o funcionamento do cérebro humano em uma máquina. O campo passou por várias fases de interesse, crítica, estagnação e ressurgimento, e hoje representa uma das áreas mais ativas e promissoras da inteligência artificial.

Os diferentes tipos de algoritmos de Machine Learning (ML) podem ser divididos conforme as seguintes categorias:

Aprendizagem Supervisionada: neste caso, o algoritmo aprende em um conjunto de dados rotulado, fornecendo uma chave de resposta que o algoritmo pode usar para avaliar sua precisão nos dados de treinamento. É chamado de "aprendizagem supervisionada" porque o processo de aprendizagem de um algoritmo a partir do conjunto de dados de treinamento pode ser pensado como um professor supervisionando o processo de aprendizagem.


Aprendizagem não-supervisionada: algoritmos de ML não-supervisionados inferem padrões de um conjunto de dados sem referência a resultados conhecidos ou rotulados. Isso é usado quando as informações usadas para treinar não são classificadas nem rotuladas.

Aprendizado por reforço: é um tipo de algoritmo de ML baseado na ideia de agentes que realizam ações em um ambiente para atingir um objetivo. O agente é recompensado ou penalizado (com pontos) pelas ações que realiza. Seu objetivo é acumular o máximo de pontos, por isso deve aprender a realizar as ações que rendem mais recompensas.

Esses diferentes tipos de ML podem ser aplicados em uma ampla gama de setores, desde saúde até finanças, e são frequentemente usados em sistemas para recomendar produtos, prever tendências de mercado, reconhecer padrões em dados e muito mais.


Uma outra família de técnicas de ML que vale a pena citar são os **Algoritmos Genéticos e Evolucionários**. Esses algoritmos aplicam os princípios da evolução encontrados na natureza ao processo de treinamento de um modelo de IA, incorporando recursos como a seleção natural darwiniana e a aleatoriedade das mutações. Nesse processo, uma população de diferentes “soluções” possíveis é criada e, em seguida, “peneirada” por meio da seleção natural, sobrevivendo apenas aqueles que produzem os melhores resultados. Uma nova geração de indivíduos (soluções possíveis) é então criada junto com os sobreviventes por meio de “mutações” que introduzem mudanças aleatórias em partes do código dos modelos sobreviventes (indivíduos). O processo de seleção natural pode então ser executado repetidas vezes para produzir uma solução ótima [11].

A Figura 2 apresenta uma pequena lista retrospectiva sobre a evolução da IA de forma geral. Essa lista não é exaustiva, mas simplesmente um pequeno conjunto de alguns exemplos da história do desenvolvimento da IA.



1950s

- O termo "Inteligência Artificial" é cunhado.
- O modelo matemático do neurônio biológico (Perceptron) é criado.
- O conceito de Redes Neurais Artificiais é inventado.
- Criação da linguagem de Programação LISP.



ML


1960s

- Modelos de Machine Learning para predição são introduzidos.
- Em 1966 aparece Shakey, o primeiro robô móvel de uso geral capaz de raciocinar sobre suas próprias ações. Enquanto outros robôs eram programados para execução de etapas individuais, Shakey podia analisar a tarefa e separá-la em partes básicas por si só.




1970s

- Em 1969 é publicado o trabalho de Minsky e Papert levantando dúvidas sobre a capacidade das Redes Neurais Artificiais. Inaugurando assim o 1º Inverno da IA.
- A linguagem de Programação PROLOG para desenvolvimento de Sistemas Especialistas (com máquina de inferência automatizada) é inventada.




1980s

- No início da década são construídas as máquinas LISP para aplicação de Sistemas Especialistas.
- Os Algoritmos Genéticos tem sua aplicação prática popularizada.
- Acontece o 2º Inverno da IA durante os anos de 1987 a 2000, por causa da falta de aplicações reais para os Sistemas Especialistas.
- A impotência das Redes Neurais Artificiais na solução de problemas de reconhecimento de padrões para dados não-lineares foi eliminada por Rumelhart, Hinton e Williams em 1986 com a técnica de treinamento Backpropagation.




1990s

- Os projetos de Sistemas Especialistas usando PROLOG foram abandonados.
- TD-Gammon mostra a força do Reinforcement Learning.
- Primeiras experiências em Laboratório com Carros Autônomos.
- DeepBlue da IBM se torna um campeão de xadrez em 1997.



2000s

- In 2006, Geoffrey Hinton publica o paper que marca o nascimento do Deep Learning, mostrando que o computador podia ser treinado para reconhecimento de padrões em imagens.



2010s

- Em 2011 o IBM Watson vence o show Jeopardy!
- Em 2016 o AlphaGo vence uma competição contra o lendário jogador de GO, Lee Sedol — considerado o maior jogador de GO da história. A disputa é assistida por mais de 200 milhões de pessoas em todo o mundo.



2020s e além...

- Em 2022 a OpenAI lança para o público a ferramenta de LLM ChatGPT.
- A computação quântica é aplicada para resolver problemas de logística no porto da cidade de Los Angeles, utilizando técnicas de otimização de IA.

Figura 2. – Retrospectiva da IA. Baseado em [12].

1.2. – Principais Técnicas

O objetivo desta seção é apresentar de forma sucinta as ideias básicas por trás das principais técnicas de Machine Learning que estão sendo utilizadas atualmente.

Uma das principais famílias de técnicas são as Redes Neurais Artificiais (Artificial Neural Network - ANN). As Redes Neurais Artificiais são como o cérebro da inteligência artificial, inspiradas no funcionamento do nosso próprio cérebro.

O principal bloco de construção das ANN é o neurônio artificial, também conhecido como Perceptron. O Perceptron é uma unidade que recebe informações, realiza cálculos, aplica uma função de ativação e transmite o resultado para os neurônios das próximas camadas. Um exemplo de neurônio pode ser observado na Figura 2.




Figura 3. – Modelo Não-linear do Neurônio.
Baseado em [13].

O neurônio artificial é como uma pequena máquina de decisão. Ele recebe entradas, cada uma multiplicada por um peso, soma tudo e passa o resultado por uma função de ativação. Essa função, como por exemplo, a função sigmoide, introduz não-linearidade, permitindo que a rede aprenda relações complexas nos dados. O modelo matemático de um neurônio “encapsula” essa operação, com pesos ajustados durante o treinamento para melhorar o desempenho da rede.

Embora essa topologia tenha suas limitações, o sistema pode modelar funções não-linearmente separáveis quando múltiplos Perceptrons são organizados em uma estrutura de rede multicamada. O treinamento de tais redes multicamadas é comumente realizado usando o algoritmo de retropropagação supracitado.

Assim sendo, as redes neurais são estruturadas em camadas, conforme Figura 4. Essas Redes Neurais, conhecidas como Multilayer Perceptrons (MLP) são redes feed-forward totalmente conectadas com pelo menos três camadas (entrada, saída e pelo menos uma camada oculta).




Figura 4. – Multilayer Perceptrons (MLP).
Baseado em [14].

A camada de entrada recebe dados, as camadas ocultas processam essas informações e a camada de saída produz o resultado final. A profundidade da rede é determinada pelo número de camadas ocultas e influencia a capacidade da rede de aprender e generalizar para novos dados. Durante a etapa de treinamento da rede, uma técnica de otimização ajusta os pesos da rede para minimizar uma “função perda” [15].

Deep Learning

Deep Learning refere-se a uma classe de algoritmos de aprendizado de máquina que visa aprender representações de dados por meio de **redes neurais com um número muito grande de camadas** (layers). Essas técnicas têm demonstrado sucesso notável em uma variedade de tarefas, incluindo visão computacional, processamento de linguagem natural e reconhecimento de padrões.

O Deep Learning representa uma das mais poderosas técnicas do Machine Learning, permitindo que computadores aprendam representações complexas de dados mediante hierarquias de características. Enquanto já revolucionou diversas áreas, continua sendo um campo ativo de pesquisa, com novas arquiteturas, técnicas e aplicações emergindo regularmente.

As arquiteturas de Deep Learning são compostas por múltiplas camadas de neurônios artificiais. Os principais tipos de redes utilizadas são: redes neurais convolucionais (CNNs), redes neurais recorrentes (RNNs), autoencoders e redes generativas adversariais (GANs), entre outras [16].

Apesar do seu sucesso, o Deep Learning também possui desafios, como a necessidade de grandes volumes de dados para treinamento, elevada demanda computacional, e a falta de interpretabilidade dos modelos.

Regressão Linear

A regressão linear é um método estatístico que visa modelar e estudar a relação entre uma variável dependente e uma ou mais variáveis independentes. A técnica é usada para entender como a variável

dependente se modifica em função das variáveis independentes e, assim, fazer previsões ou inferências.

A regressão linear simples envolve apenas uma variável independente e pode ser representada por uma linha reta em um gráfico bidimensional, com a seguinte equação geral da reta:

$$Y = \beta_0 + \beta_1 * X$$

No qual Y é a variável que se deseja prever, X é a variável independente, β_0 é o coeficiente de interceptação quando X é igual a zero e β_1 é o coeficiente de regressão, que irá representar a mudança do valor procurado Y de acordo com a variação em X.

Na regressão linear múltipla, há mais de uma variável independente, e a equação se torna mais complexa:

$$Y = \beta_0 + \sum_1^n (\beta_i * X_i)$$

Nesse caso, cada coeficiente β_i representa o impacto específico de cada variável independente X_i na variável dependente Y, mantendo as demais variáveis independentes constantes.

A regressão linear múltipla oferece uma abordagem simples e interpretável para modelar e analisar relações lineares entre variáveis.

Árvore de Decisão

Árvores de Decisão, ou Decision Trees, são algoritmos de ML (Machine Learning) largamente utilizados, com uma estrutura de simples compreensão e que costumam apresentar bons resultados em suas previsões [15]. Esse modelo é utilizado para tomar decisões ou classificar dados em uma estrutura semelhante a um fluxograma. Ela é uma representação gráfica de todas as decisões possíveis que podem ser tomadas a partir de um conjunto de atributos, levando a diferentes resultados.

Em uma árvore de decisão, cada nó representa um atributo, e cada ramificação a partir desse nó representa uma decisão com base em um valor específico desse atributo. Os nós folha da árvore representam os resultados finais ou as classes a que os dados pertencem.

O processo de construção de uma árvore de decisão envolve dividir os dados em subconjuntos cada vez mais puros ou homogêneos, com o objetivo de maximizar a homogeneidade das classes nos nós folha.

As árvores de decisão são frequentemente usadas em problemas de classificação e regressão, e são muito populares devido à sua interpretabilidade e simplicidade, como mostrado na Figura 5. Além disso, elas podem ser aplicadas a conjuntos de dados numéricos e categóricos.




Figura 5. – Árvore de Decisão (Decision Tree).
Fonte: [17].

Support Vector Regression (SVR)

Support Vector Regression (SVR) é usado para casos de predição de regressão e pode ser considerado como uma generalização do método Support Vector Machine (SVM), utilizado para os casos de classificação. Sendo assim, seu princípio de funcionamento segue a mesma vertente do SVM, tentando resolver os problemas de classificação binária pela formulação deles como se fossem problemas de otimização de funções convexas.

Em ambas as técnicas, o principal objetivo é encontrar a máxima margem capaz de separar um hiperplano que corta o gráfico da função enquanto classifica corretamente a maior quantidade de pontos de treinamento possível. A maior diferença entre os dois métodos é o fato de no SVR, além de ser formado o hiperplano, também existe a formação de um tubo de menor diâmetro possível com o objetivo de minimizar o erro de predição [18]. Isso pode ser feito de maneira linear (Figura 6) ou não linear (Figura 7).




Figura 6. – SVR linear.
Fonte: [17].




Figura 7. – SVR não-linear.
Fonte: [17].

Random Forest

A técnica Random Forest, proposta por Breiman (2001), é uma técnica que combina múltiplas Árvores de Decisão em um único modelo. O Random Forest visa criar um modelo mais robusto e preciso, minimizando os problemas associados a uma única árvore de decisão. Para tarefas de classificação, o Random Forest realiza uma votação entre todas as árvores no conjunto e atribui a classe que obtém a maioria dos votos como previsão final. Para tarefas de regressão, é calculada a média das previsões de todas as árvores.

As principais vantagens do Random Forest incluem sua robustez, capacidade de lidar com grandes volumes de dados e com atributos irrelevantes. Uma desvantagem é que os modelos podem ser complexos e, portanto, desafiadores de interpretar em comparação com uma única árvore de decisão.

REFERÊNCIAS DO CAPÍTULO 1

- [1] - Mustafa Suleyman e Michael Bhaskar, **“A Próxima Onda: inteligência artificial, poder e o maior dilema do século XXI”**, Editora Record, 2023.
- [2] - BBC News Brasil, **“A Inteligência Artificial vai ser adorada como um deus?”**, 22 julho 2023, ([link](#)).
- [3] - New York Times, by Rebecca Carballo, **“Using A.I. to Talk to the Dead”**, Dec. 11, 2023, ([link](#)).
- [4] - The Economist, **“Just how rich are businesses getting in the AI gold rush? - Nvidia and Microsoft are not the only winners”**, Mar 17th 2024, ([link](#)).
- [5] - Richard Evans and Jim Gao, **“DeepMind AI Reduces Google Data Centre Cooling Bill by 40%”**, DeepMind, July 20, 2016, ([link](#)).
- [6] - Hariom Tatsat, Sahil Puri and Brad Lookabaugh, **“Machine Learning and Data Science Blueprints for Finance: From Building Trading Strategies to Robo-Advisors Using Python”**, 1st Edition, O'Reilly Media, December 2020.
- [7] - Warren S. McCulloch and Walter Pitts, **“A logical calculus of the ideas immanent in nervous activity”**, The bulletin of mathematical biophysics , Volume 5, 1943. <https://doi.org/10.1007/BF02478259>.
- [8] - F Rosenblatt, **“The perceptron: A probabilistic model for information storage and organization in the brain”**, Psychological Review, Volume 65(6), 1958. <https://doi.org/10.1037/h0042519>.
- [9] - M. Minsky and S. Papert, **“Perceptrons: An Introduction to Computational Geometry”**, MIT Press, 1969.

- [10] - David E. Rumelhart, Geoffrey E. Hinton and Ronald J. Williams, “**Learning representations by back-propagating errors**”. Nature, Volume 323, pages 533-536, 1986, <https://doi.org/10.1038/323533a0>.
- [11] - Randy L. Haupt and Sue Ellen Haupt, “**Practical Genetic Algorithms**”, Wiley-Interscience, 2nd edition, May 31, 2004.
- [12] - Rishal Hurbans, “**Grokking Artificial Intelligence Algorithms**”, Manning, 2020.
- [13] - Mayank Banoula, “**What is Perceptron: A Beginners Guide for Perceptron**”, Last updated on May 10, 2023, <https://www.simplilearn.com/tutorials/deep-learning-tutorial/perceptron>
- [14] - Peter Norvig and Stuart Russell, “**Artificial Intelligence: A Modern Approach, Global Edition**”, Pearson, 4th edition, May 13, 2021.
- [15] - A. Géron, “**Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow**”, O'Reilly Media, Inc., 2022.
- [16] - Ian Goodfellow, Yoshua Bengio and Aaron Courville, “**Deep Learning**”, The MIT Press, 2016.
- [17] - DIDATICA TECH, “**Como funciona o algoritmo de árvore de decisão**”, Disponível em: <https://didatica.tech/como-funciona-o-algoritmo-arvore-de-decisao/>. Acesso em: 08 jul. 2023.
- [18] - Mariette Awad and Rahul Khanna, “**Efficient Learning machines: Theories, Concepts and Applications for Engineers and System Designers**”. Publisher: Apress, 1st edition, 2015.

Capítulo 2

Revisão do Uso Internacional

Dada a importância do preço da energia elétrica para a tomada de decisões quanto a aspectos da geração e comercialização, os pesquisadores e as empresas têm empenhado muito tempo e energia no desenvolvimento de técnicas para previsão do preço da energia. Por esta razão, muitos estudiosos têm proposto uma série de soluções para a previsão, não somente de preços de energia elétrica, mas também de preços de várias commodities, inclusive criptomoedas. Segue abaixo uma revisão bibliográfica de alguns trabalhos deste tipo:

Huang *et al.*, [1] propôs uma abordagem inovadora para aprimorar a precisão na previsão de carga e reduzir os custos de energia. O objetivo do trabalho foi fazer com que as Entidades Servidoras de Carga (LSEs - Load Serving Entities) não percam dinheiro ao terem que comprar energia no Real-Time Market (RTM) porque fizeram uma previsão de consumo de energia dos seus clientes no DAM (Day-ahead Market) abaixo do que está sendo consumido em tempo real. O modelo proposto utilizou um Deep LSTM (Long Short-Term Memory), não somente para melhorar a precisão da previsão do MW consumido nas próximas horas, mas também para diminuir o custo de comprar energia no RTM. Para isso, os autores criaram uma função de perdas chamada CCF (Costing Correlated Factor);

Gong e Zhang [2] propuseram uma abordagem para a previsão de preços de commodities por meio da técnica de Ensemble Learning. Essa técnica de Machine Learning aumenta a precisão nas previsões, mesclando previsões de vários modelos. O objetivo é mitigar erros que possam existir em modelos individuais, aproveitando a inteligência coletiva do conjunto (ensemble). O método dos autores utiliza cinco classificadores distintos, incluindo: Decision Tree, SVM, KNN, Random Forest e Regressão Linear. Vale observar que os autores não utilizaram as Redes Neurais Artificiais no trabalho;

Patra e Mohanty [3] abordaram a previsão de preços de criptomoedas, com foco em Bitcoin, Ethereum e Dogecoin. O modelo, baseado em uma arquitetura de Rede Neural recorrente com GRU (Gated Recurrent Unit), supera modelos concorrentes, incluindo LSTM e GRU de uma única camada, ao longo de um período de 21 dias. Embora o modelo exija uma capacidade computacional mais robusta, os resultados sugerem vantagens promissoras na previsão de curto prazo para criptomoedas;

Yousefi, Sianaki e Sharafi [4] propõem uma estratégia na previsão de longo prazo dos preços médios mensais da energia elétrica, concentrando-se no mercado da Califórnia de 2001 a 2017. O objetivo do trabalho foi antecipar o preço médio mensal da eletricidade nos próximos cinco anos. O trabalho adota um modelo que é comumente conhecido como previsão “Feature-based”. Ou seja, os dados de entrada para o modelo de previsão não são somente os valores da série temporal do preço, também são utilizados outros dados do mercado de energia que estão correlacionados com o preço da energia elétrica. Por exemplo, os autores utilizaram a quantidade de gás natural consumida pelo setor elétrico, além da geração das fontes renováveis e outras grandezas. Os autores não utilizaram a técnica de Redes Neurais;

Jiang and Hu [5] apresentam um trabalho para previsão de preços de eletricidade day-ahead usando um modelo de Long-Short Term Memory (LSTM). Esse modelo, comumente utilizado em processamento de linguagem natural e análise de séries temporais, pode aprender com dados históricos para prever preços futuros de eletricidade. O modelo LSTM leva em conta não apenas os preços históricos, mas também variáveis exógenas como: feriados, dia da semana, hora do dia, condições climáticas, preços do petróleo e preço/demanda históricos;

Baltaoglu, Tong e Zhao [6] consideraram o problema do “*bidding*” para negociação virtual em mercados de eletricidade com duas liquidações. Um trader virtual visa arbitrar diferenças entre os preços de mercado do dia seguinte (day-ahead) e em tempo real (real-time). Os preços real-time são aleatórios e desconhecidos pelos participantes do mercado. Um algoritmo de aprendizagem on-line é proposto para maximizar o retorno cumulativo ao longo de um número finito de sessões de negociação, alocando o orçamento do trader entre suas ofertas em cada sessão. O algoritmo proposto também é generalizado para estratégias de negociação com medida de risco. Usando o retorno acumulado e o índice de Sharpe como métricas de desempenho, as avaliações foram realizadas com base nos dados históricos abrangendo o período de dez anos dos mercados NYISO e PJM. Foi demonstrado que a estratégia proposta supera os benchmarks padrão e o índice S&P 500 no mesmo período.

Hong e P. Wang [7] no trabalho intitulado “*Artificial Intelligence for Load Forecasting: History, Illusions, and Opportunities*” após extensa análise da literatura, chegaram à conclusão que, a maioria dos modelos de RNA publicados não recebeu muita atenção das empresas do mercado de energia elétrica. No entanto, um ramo de pesquisa conseguiu fazer da previsão de carga uma das aplicações das Redes Neurais Artificiais (RNA) mais bem-sucedidas da história, transformando as RNAs no cavalo de batalha da previsão de série temporal em todo o mundo. Em 1995, o *IEEE Transactions on Power Systems* publicou um artigo descrevendo um sistema de previsão de carga baseado em RNAs, que foi implementado em 20 concessionárias (*utilities*) dos Estados Unidos e utilizado por várias delas. O sistema foi posteriormente denominado *ANN short-term load forecaster (ANNSTLF)*. Em 1997, o *IEEE Transactions on Neural Networks* publicou um artigo descrevendo a segunda geração do ANNSTLF, com 32 concessionárias nos Estados Unidos e Canadá usando o sistema. Um ano depois, o *IEEE Transactions on Power Systems* publicou um artigo descrevendo a terceira geração de ANNSTLFs usados por 35 concessionárias nos Estados Unidos e Canadá.

Hong e Wang também examinam em seu trabalho as cinco ilusões mais associadas ao desenvolvimento de modelos baseados em IA e também apresentam soluções e esclarecimentos para ajudar a melhorar a eficiência da IA para previsão de carga, dadas as oportunidades na atual era do big data. Conforme a Figura 8, publicada no trabalho de Hong e Wang [7], percebe-se um grande número de publicações recentes utilizando Deep Learning para previsão de carga.




Figura 8. – Publicações com “load forecasting” no título e “AI/ML techniques” no abstract.
Fonte: [7]

Kell, McGough e Forshaw em [8] sugerem que simulações baseadas em agentes (*agent-based simulations*) sejam utilizadas para melhor compreender a dinâmica do mercado de eletricidade, dado que existem uma grande quantidade de variáveis e dados de entrada para poder entender o funcionamento desses mercados, e que estas variáveis e dados comportam-se por vezes de formas que não podem ser previstas a priori. Os modelos baseados em agentes oferecem a oportunidade de integrar a aprendizagem automática e a inteligência artificial para adicionar inteligência, fazer melhores

previsões e controlar o mercado de energia de formas melhores e mais eficientes. Na revisão sistemática da literatura realizada por Kell, McGough e Forshaw foram revisados 55 artigos publicados entre 2016 e 2021 que enfocam o Machine Learning aplicado a modelos de mercado de eletricidade baseados em agentes (*agent-based electricity market models*). Os autores descobriram que grande parte dos artigos revisados se concentra no tópico bastante popular do *bidding strategy*. Mas ressaltam que, no entanto, existe uma longa cauda de aplicações das *agent-based simulations* que poderiam beneficiar grande parte da comercialização de energia.

Mohammadi, *et al.*, no trabalho intitulado “*A Review of Machine Learning Applications in Electricity Market Studies*” [9], fazem uma revisão dos desenvolvimentos mais recentes das técnicas de Machine Learning e suas aplicações em mercados de energia elétrica. Os autores tabelam os vários desafios enfrentados pelos agentes do mercado e para cada desafio quais são as diferentes abordagens de Machine Learning para solucioná-los. Os autores também sugerem, de forma muito pertinente várias direções para futuras pesquisas.

Liu, Zhang e Gooi em [10] apresentam uma técnica de Deep Q-Learning (DQN) para os comercializadores varejistas, com o objetivo de melhorar a tomada de decisão, bem como promover a maximização da rentabilidade dos varejistas no mercado de energia elétrica.

Malte Lehna, *et al.*, em [11], propõem uma abordagem baseada em algoritmos de Deep Reinforcement Learning (DRL) como uma solução para o problema de comercialização dos produtores eólicos nos mercados intradiários. Os mercados intradiários, largamente utilizados na Europa, contribuem para que os agentes possam lidar com a volatilidade do fornecimento da fonte eólica. Através do seu horizonte de negociação curto, os mercados intradiários oferecem a capacidade de ajustar as decisões de negociação do mercado *day-ahead* para uma condição mais próxima do tempo real, reduzindo assim o risco de negociação em curto prazo. Para tanto, os autores modelaram a negociação intradiária como um Processo de Decisão de Markov e empregaram o algoritmo de “Proximal Policy Optimization” (PPO) como a abordagem para o DRL. O algoritmo PPO é um dos mais importantes algoritmos no campo do Reinforcement Learning. O PPO foi desenvolvido por John Schulman em 2017 [12] e se tornou o algoritmo de Reinforcement Learning padrão da empresa americana de inteligência artificial OpenAI.

Julius Trebbien, *et al.*, em [13], propõem um modelo de Machine Learning Explicável (Explainable Machine Learning), projetado para uma análise dos preços de eletricidade no mercado day-ahead da Alemanha, usando valores SHapley Additive exPlanation (SHAP). Os autores argumentam que o trabalho oferece um modelo que descreve a influência dos principais fatores nos preços da eletricidade, levando os agentes um passo adiante do princípio da ordem de mérito. A Figura 9 apresenta um resumo da ideia e do trabalho dos autores. Os autores defendem que avaliar a dinâmica dos preços de eletricidade usando somente o princípio da ordem de mérito apresenta severas limitações pelas suas simplificações. Sabe-se que nos mercados mais avançados de energia elétrica os preços são determinados pelo livre encontro entre oferta e demanda dos agentes (e não por regras codificadas em algum programa de computador, como no Brasil). Este livre encontro, por sua vez, é impulsionado por diversos fatores externos que possuem suas próprias volatilidades no tempo e nas características técnicas operacionais. O princípio da ordem de mérito (advindo da teoria econômica para explicar o funcionamento dos mercados perfeitamente competitivos) descreve que as centrais elétricas despacháveis entram no mercado pela ordem dos seus custos marginais para satisfazer a carga residual, ou seja, a diferença entre a carga e a geração renovável. Os autores argumentam que os modelos matemáticos que tentam prever os preços da eletricidade baseados no princípio da ordem de mérito, estão repletos de suposições e simplificações e, portanto, são limitados em sua capacidade de previsão precisa dos preços de eletricidade.

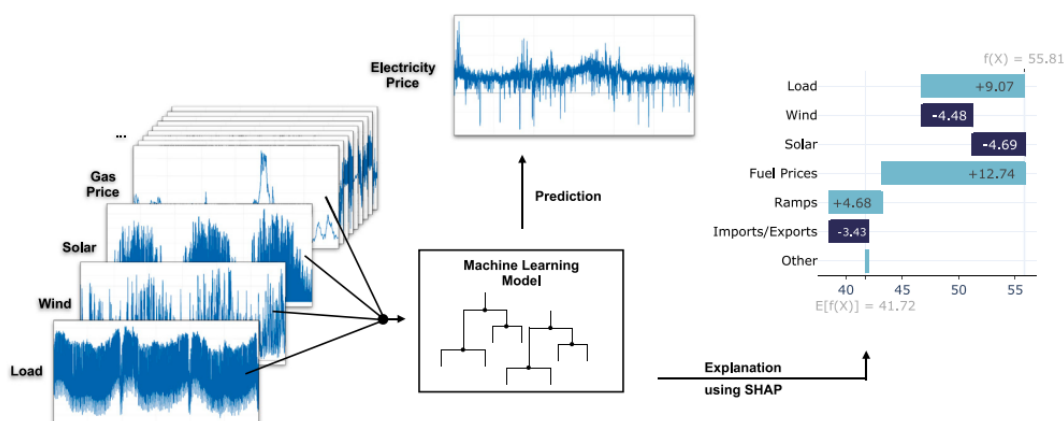
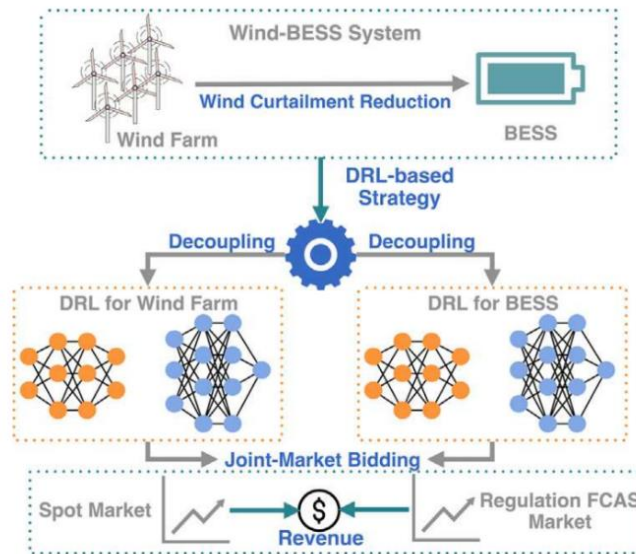


Figura 9. – Fluxograma básico da abordagem proposta pelos autores em [13].
Fonte: [13]

Em [14], J. Li, C. Wang e H. Wang, apresentaram um trabalho muito interessante intitulado “*Deep reinforcement learning for wind and energy storage coordination in wholesale energy and ancillary service markets*”. Neste trabalho os autores propõem um modelo de tomada de decisão baseado em Deep Reinforcement Learning (DRL). A ideia básica é aumentar o custo-benefício da operação conjunta de um parque eólico e de um BESS (Battery Energy Storage System) em ambos os mercados SPOT (também conhecido como *real-time market*) e FCAS (Frequency Control Ancillary Services), na Austrália. O armazenamento da energia eólica, depende dos custos variáveis e fixos do armazenamento no BESS e da estratégia de coordenação subjacente entre os ativos de produção em ambos os mercados SPOT e FCAS. Vale ressaltar que ambos os mercados na Austrália são mercados competitivos, ou seja, o empreendedor tem que elaborar o seu *bid* para poder competir nestes mercados de curto-prazo. Os autores validaram a técnica apresentada num caso real e chegaram à conclusão de que a estratégia de *bidding* coordenado, superou o benchmark baseado em otimização tradicional, com o aumento de receitas em aproximadamente 25%. Os resultados mostraram que a estratégia de *bidding* coordenado pelos dois ativos nos dois mercados (SPOT e FCAS) pode melhorar significativamente o desempenho financeiro dos sistemas híbridos, BESS mais parques eólicos, em comparação com a participação em cada mercado separadamente. A Figura 10 apresenta um resumo da ideia e do trabalho dos autores.



**Figura 10. – Fluxograma básico da abordagem proposta pelos autores em [14].
Fonte: [14]**

Para concluir esta pequena revisão bibliográfica da literatura internacional, é importante citar dois trabalhos que são exatamente uma revisão sobre a aplicação das técnicas de inteligência artificial nos sistemas de energia.

Em [15] D. Cao, conjuntamente com vários colegas da China, dos USA e da Dinamarca, realizaram uma análise dos algoritmos de Reinforcement Learning (RL) e suas aplicações em sistemas de potência e energia. Várias aplicações de algoritmos de RL são relatadas, incluindo a otimização de redes de distribuição e microrredes, gestão de energia, mercado de eletricidade, resposta à demanda e controle de operação.

Em [16] F. Heymann, *et al.*, fizeram uma análise de 258919 publicações em IA, baseada numa pesquisa Web, entre os anos de 1982 e 2022. O objetivo da análise foi tentar revelar quais são os maiores potenciais de aplicação de IA em sistemas de energia. A Figura 11 apresenta o número de publicações anuais de aplicações de IA no setor elétrico e sua divisão por área de atividade.




Figura 11. – Evolução do número de publicações anuais de pesquisa em IA nos últimos 40 anos, categorizadas por atividades no setor elétrico.

Fonte: [16]

REFERÊNCIAS DO CAPÍTULO 2

- [1] - B. Huang, *et al.*, “**Load Forecasting based on Deep Long Short-term Memory with Consideration of Costing Correlated Factor**”, IEEE 16th International Conference on Industrial Informatics (INDIN), Porto, Portugal, 2018, pp. 496-501, DOI: 10.1109/INDIN.2018.8472040.
- [2] - Y. Gong, and P. Zhang, “**Commodity Price Analysis and Prediction Based on Ensemble Learning**”, 2nd International Conference on Networking Systems of AI (INSAI), Shanghai, China, 2022, pp. 199-204, DOI: 10.1109/INSAI56792.2022.00045.
- [3] - Gyana R. Patra and Mihir N. Mohanty, “**Price Prediction of Cryptocurrency Using a MultiLayer Gated Recurrent Unit Network with Multi Features**”, Comput Econ 62, 1525–1544, 2023, <https://doi.org/10.1007/s10614-022-10310-1>.
- [4] - A. Yousefi, O. A. Sianaki and D. Sharafi, “**Long-Term Electricity Price Forecast Using Machine Learning Techniques**”, 2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia), Chengdu, China, 2019, pp. 2909-2913, doi: 10.1109/ISGT-Asia.2019.8881604.
- [5] - L. Jiang and G. Hu, “**Day-Ahead Price Forecasting for Electricity Market using Long-Short Term Memory Recurrent Neural Network**”, 2018 15th International Conference on Control, Automation, Robotics and Vision (ICARCV), Singapore, 2018, pp. 949-954, doi: 10.1109/ICARCV.2018.8581235.
- [6] - S. Baltaoglu, L. Tong, and Q. Zhao, “**Algorithmic Bidding for Virtual Trading in Electricity Markets**”, in IEEE Transactions on Power Systems, vol. 34, no. 1, pp. 535-543, Jan. 2019, doi: 10.1109/TPWRS.2018.2862246.
- [7] - Hong and P. Wang, “**Artificial Intelligence for Load Forecasting: History, Illusions, and Opportunities**”, in IEEE Power and Energy Magazine, vol. 20, no. 3, pp. 14-23, May-June 2022, doi: 10.1109/MPE.2022.3150808.

- [8] - A. J. M. Kell, A. Stephen McGough and M. Forshaw, “**A systematic literature review on machine learning for electricity market agent-based models**”, 2022 IEEE International Conference on Big Data (Big Data), Osaka, Japan, 2022, pp. 4503-4512, doi: 10.1109/BigData55660.2022.10020902.
- [9] - S. Mohammadi, M. R. Hesamzadeh, A. Vafamehr and F. Ferdowsi, “**A Review of Machine Learning Applications in Electricity Market Studies**”, 2020 3rd International Colloquium on Intelligent Grid Metrology (SMAGRIMET), Cavtat, Croatia, 2020, pp. 1-8, doi: 10.23919/SMAGRIMET48809.2020.9264022.
- [10] - Y. Liu, D. Zhang and H. B. Gooi, “**Data-driven decision-making strategies for electricity retailers: A deep reinforcement learning approach**”, in CSEE Journal of Power and Energy Systems, vol. 7, no. 2, pp. 358-367, March 2021, doi: 10.17775/CSEEJPES.2019.02510.
- [11] - Malte Lehna, Björn Hoppmann, Christoph Scholz, René Heinrich, “**A Reinforcement Learning approach for the continuous electricity market of Germany: Trading from the perspective of a wind park operator**”, Energy and AI, Volume 8, 2022, <https://doi.org/10.1016/j.egyai.2022.100139>.
- [12] - J. Schulman, F. Wolski, P. Dhariwal, A. Radford, and O. Klimov, “**Proximal policy optimization algorithms**”, Submitted on 20 Jul 2017 (v1), last revised 28 Aug 2017 (this version, v2), arXiv.org, <https://arxiv.org/abs/1707.06347>.
- [13] - Julius Trebbien, Leonardo Rydin Gorjão, Aaron Praktijnjo, Benjamin Schäfer, Dirk Witthaut, “**Understanding electricity prices beyond the merit order principle using explainable AI**”, Energy and AI, Volume 13, 2023, <https://doi.org/10.1016/j.egyai.2023.100250>.
- [14] - Jinhao Li, Changlong Wang, Hao Wang, “**Deep reinforcement learning for wind and energy storage coordination in wholesale energy and ancillary service markets**”, Energy and AI, Volume 14, 2023, <https://doi.org/10.1016/j.egyai.2023.100280>.
- [15] - Di Cao, Weihao Hu, Junbo Zhao, Guozhou Zhang, Bin Zhang, Zhou Liu, Zhe Chen and Frede Blaabjerg, “**Reinforcement Learning and Its Applications in Modern Power and Energy Systems: A Review**”, in Journal of Modern Power Systems and Clean Energy, vol. 8, no. 6, pp. 1029-1042, November 2020, doi: 10.35833/MPCE.2020.000552.
- [16] - F. Heymann, H. Quest, T. Lopez Garcia, C. Ballif, M. Galus, “**Reviewing 40 years of artificial intelligence applied to power systems – A taxonomic perspective**”, Energy and AI, Volume 15, 2024, <https://doi.org/10.1016/j.egyai.2023.100322>.

Capítulo 3

Revisão do Uso Nacional

Segue abaixo uma revisão bibliográfica de alguns trabalhos de pesquisadores e empresas brasileiras com aplicações das técnicas de Machine Learning na comercialização de energia elétrica:

Ewerton Guarnier, *et al.*, [1] desenvolveram uma ferramenta para previsão dos preços de energia elétrica do mês seguinte, aplicando técnicas de Inteligência Artificial, em comparação a métodos estatísticos clássicos. No caso deste trabalho, o modelo desenvolvido foi o LightGBM. Para construção das séries temporais históricas de preços M+1 (um mês a frente), foram utilizadas todas as operações negociadas na BBCE entre 2016 e 2023 relacionadas ao submercado Sudeste/Centro-Oeste, para fonte Convencional, a preço fixo. O erro percentual médio apresentou-se em torno de 6%.

Já no âmbito da otimização da carteira de contratos, o trabalho de Mateus Balan, *et al.*, [2] implementa a otimização da carteira via Algoritmos Genéticos, como alternativa às técnicas de otimização clássicas. Os autores consideraram no seu trabalho as variáveis críticas na formação do preço dos contratos de médio e longo prazos, tais como, flexibilidade (precificação do risco), liquidez de mercado e a evolução da tarifa no mercado regulado. Otimização da carteira teve como objetivo a maximização do binômio risco x retorno, em função do perfil de aversão ou apetite ao risco do agente. Com a otimização da carteira pode-se simular uma série de situações de contratação, como, por exemplo, a alocação ótima de contratos, avaliação de propostas, adequação de nível de risco, sazonalização de garantia física, etc.

Um outro trabalho muito interessante que também utilizou técnicas de IA para previsão dos preços de energia foi a referência [3]. Neste trabalho foram utilizadas as técnicas Random Forest e XGBoost, com foco nos curtíssimo e curto prazos. Foi realizada uma previsão do PLD horário para um mês inteiro sem atualizações intermediárias desta projeção. Os resultados obtidos apontam um erro MAPE (Mean Absolute Percentage Error) entre 7,92 e 14,06% para os vários submercados do Brasil.

Uma referência que bastante interessante para os traders de energia elétrica é a referência [4]. Neste trabalho foram avaliadas várias técnicas de Machine Learning e algumas técnicas tradicionais para geração de sinais de compra e venda com base nas operações reais da BBCE. Alguns dos vários modelos analisados apresentaram uma acurácia de aproximadamente 68% na geração dos sinais de compra e venda.

Um outro trabalho interessante, mas com um sabor de aplicação futura, é a referência [5]. Nela, os autores tinham como objetivo determinar a melhor estratégia de operação de uma planta virtual (*virtual power plant*) de energia para o dia seguinte. A planta utilizada neste trabalho é composta de: uma geração térmica convencional, conectada na distribuição e não despachada centralizadamente; um parque eólico; uma unidade de armazenamento de energia com bateria de íon-lítio; e um consumidor com demanda flexível. Esta planta virtual participa dos mercados de eletricidade e de serviços ancilares disponíveis atualmente no Brasil. Neste trabalho a otimização estocástica foi executada utilizando-se a técnica de Algoritmos Genéticos, atendendo uma métrica de risco.

M. Nasser em [6] aplicou as principais técnicas de Machine Learning para explorar dados horários, obtidos dos portais da CCEE e do ONS, relacionados à comercialização de energia elétrica no Brasil. Ao analisar essas informações, o autor identificou padrões, tendências e anomalias, especialmente no Custo Marginal de Operação (CMO).

REFERÊNCIAS DO CAPÍTULO 3

[1] - Ewerton Guarnier, *et al.*, “**Inteligência Artificial Aplicada à Previsão da Tendência no Preço de Mercado para Energia**”, XXVII SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica, 26 a 29 de novembro de 2023, Brasília-DF.

[2] - Mateus Balan, *et al.*, “**Sistema Integrado de Apoio à Decisão para Definição da Estratégia Ótima de Comercialização de Energia Elétrica de Um Agente Gerador**”, XXVI SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica, 15 a 18 de maio de 2022, Rio de Janeiro - RJ.]

[3] - Cosme dos Santos, Roberto Castro e Rafael Marques, “**Aprendizado de Máquina no Suporte às Decisões no Mercado de Energia Elétrica**”, XXVI SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica, 15 a 18 de maio de 2022, Rio de Janeiro - RJ.]

[4] - Raphael Piovezan, *et al.*, “**Proposta de Modelo à Análise Técnica Aplicada ao Mercado de Curto Prazo de Energia Elétrica**”, XXVII SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica, 26 a 29 de novembro de 2023, Brasília-DF.]

[5] - Eduardo Sodré, *et al.*, “**Análise de Risco em Comercialização de Energia de Usina Virtual no Mercado Brasileiro**”, XXVI SNPTEE - Seminário Nacional de Produção e Transmissão de Energia Elétrica, 15 a 18 de maio de 2022, Rio de Janeiro – RJ.].

[6] M. H. Nasser, “**Ciência de Dados Aplicada na Exploração de Conhecimento de Dados Abertos na Comercialização de Energia Elétrica**”, Trabalho de Graduação em Engenharia de Energia, Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas, Universidade Federal do ABC (UFABC), 2023.

Capítulo 4

Conclusões e Visão de Futuro

Para abrir este capítulo intitulado “Conclusões e Visão de Futuro” é importante lembrar das palavras do Marcos Lopez de Prado, um dos grandes especialistas em aplicações de IA no Mercado Financeiro. Marcos trabalha, desde 2020, como *Global Head* de pesquisa e desenvolvimento quantitativo na ADIA (Abu Dhabi Investment Authority), um dos maiores fundos soberanos do mundo. Antes da ADIA, ele fundou a True Positive Technologies LP (TPT), uma empresa que licenciou e vendeu diversas patentes para alguns dos maiores fundos de investimento em negócios de 8 dígitos. E antes da TPT, Marcos foi sócio e primeiro *Head* de Machine Learning da AQR Capital Management.

Seguem suas palavras [1]:

Financial problems pose a particular challenge to those legacy methods, because economic systems exhibit a degree of complexity that is beyond the grasp of classical statistical tools. As a consequence, machine learning (ML) plays an increasingly important role in finance. Only a few years ago, it was rare to find ML applications outside short-term price prediction, trade execution, and setting of credit ratings. Today, it is hard to find a use case where ML is not being deployed in some form. This trend is unlikely to change, as larger data sets, greater computing power, and more efficient algorithms all conspire to unleash a golden age of financial ML. The ML revolution creates opportunities for dynamic firms and challenges for antiquated asset managers. Firms that resist this revolution will likely share Kodak's fate.

E para a comercialização da energia, qual será o destino das aplicações de IA? Essas aplicações serão o *mainstream*?

O filósofo inglês Francis Bacon, responsável pela criação do método científico, observou em 1609 que as “artes mecânicas são de uso ambíguo, servindo tanto para ferir quanto para salvar”. Dado que a IA desempenha um papel cada vez mais importante nas esferas econômica, social, científica, médica, financeira e militar, a sociedade como um todo faria bem em considerar os riscos e benefícios que a IA pode oferecer [2].

Muitos agentes consideram a integração da IA nos sistemas elétricos uma parte crucial da transição energética. Em primeiro lugar, a integração da IA no mercado da eletricidade pode afetar positivamente os aspectos da sustentabilidade ambiental e principalmente os aspectos de confiabilidade. Com uma maior velocidade de detecção de mal funcionamento do mercado, a entidade operadora do mercado, caso da CCEE no Brasil, poderia lidar com situações de risco de forma mais rápida. Lembrando também que a integração da IA pode melhorar de forma significativa o rápido desenvolvimento dos aspectos técnicos e regulatórios dos mercados de eletricidade. Ao mesmo tempo, o mercado tornar-se-ia mais complexo e dependente de uma extensa infraestrutura digital. Isto dá origem a preocupações relativas à cibersegurança, privacidade, controle sobre a tecnologia e autonomia. Uma primeira área de investigação sobre as vantagens da aplicação das técnicas de IA nos mercados de eletricidade diz respeito as incertezas quanto ao efeito na equidade e nos equilíbrios de poder [3].

Por fim, é crucial ressaltar que já há internacionalmente uma consciência sobre a necessidade de se estabelecer limites éticos e regulatórios, considerando o papel dos órgãos governamentais, na definição de uma "fronteira saudável" para os avanços no campo da inteligência artificial e seus possíveis impactos [4].

Recentemente, em 13 de março de 2024, o Parlamento Europeu aprovou a Lei da Inteligência Artificial (*Artificial Intelligence Act*). O regulamento, acordado nas negociações com os Estados-Membros em dezembro de 2023, foi aprovado pelos deputados europeus com 523 votos a favor, 46 contra e 49 abstenções. A Lei Europeia da Inteligência Artificial tem como objetivo proteger a democracia, o Estado de direito e a sustentabilidade ambiental da IA de alto risco, ao mesmo tempo que impulsiona a inovação e estabelece a Europa como líder neste domínio.

O regulamento europeu estabelece obrigações para a IA com base nos seus riscos potenciais e no nível de impacto. As novas regras proíbem determinadas aplicações de IA que ameaçam os direitos dos cidadãos, incluindo sistemas de categorização biométrica baseados em características sensíveis e gravações de imagens faciais da Internet ou imagens de CCTV para criar bases de dados de reconhecimento facial. Também estão banidos o reconhecimento de emoções no local de trabalho e nas escolas, a pontuação social e o policiamento preditivo (quando se baseia apenas no perfil de uma pessoa ou na avaliação das suas características). As IAs que manipulam o comportamento humano ou exploram as vulnerabilidades das pessoas também estão proibidas.

Além dessas obrigações de cunho social mais amplo, também estão previstas obrigações claras para outros sistemas de IA de alto risco (devido aos seus potenciais danos significativos para a saúde, a segurança, os direitos fundamentais, o ambiente, a democracia e o Estado de direito). Exemplos de utilizações de IA de alto risco incluem infraestruturas críticas (o setor de energia principalmente), educação e formação profissional, emprego, serviços públicos e privados essenciais (por exemplo, cuidados de saúde e serviços bancários), determinados sistemas de aplicação da lei, migração e gestão de fronteiras, justiça e processos democráticos (eleições). Esses sistemas devem avaliar e reduzir os riscos, manter registos de utilização, ser transparentes e precisos e garantir a supervisão humana. Os cidadãos terão o direito de apresentar queixas sobre sistemas de IA e receber explicações sobre decisões baseadas em sistemas de IA de alto risco que afetem os seus direitos [5].

REFERÊNCIAS DO CAPÍTULO 4

[1] - Marcos M. López de Prado, “**Machine Learning for Asset Managers**”, Elements in Quantitative Finance, Cambridge University Press, Apr 30, 2020.

[2] - Peter Norvig and Stuart Russell, “**Artificial Intelligence: A Modern Approach**”, Global Edition, Pearson, 4th edition, May 13, 2021.

[3] - Irene Niet, Laura Van den Berghe, Rinie van Est, “**Societal impacts of AI integration in the EU electricity market: The Dutch case**”, Technological Forecasting and Social Change, Volume 192, 2023, 122554, ISSN 0040-1625, <https://doi.org/10.1016/j.techfore.2023.122554>.

[4] - J. Lee and L. Schu, “**Regulation of Algorithmic Trading: Frameworks for Human Supervision and Direct Market Interventions**”, European Business Law Review, Jan. 14, 2021. Available: <http://dx.doi.org/10.2139/ssrn.3765882>.

[5] – “**Artificial Intelligence Act: MEPs adopt landmark law**”, Press Releases PLENARY SESSION IMCO LIBE 13-03-2024 - 12:25, ([link](#)).