




Els trading bots: el futur del trading estratègic?

Treball de Fi de Grau



Marc Solà Delgado
Rubén Manuel Morales Oliver
URV (ADE+FiC)
Reus, 06/2025

ÍNDEX

1. Els trading bots: el futur del trading estratègic?	3
Català	3
2. Presentació del projecte	5
2.1 Motivacions	5
2.2 Temporalització	5
3.Introducció	7
3.1. Rellevància del tema d'estudi	7
3.2. Context general	8
3.3. Visió general del projecte i metodologia	9
3.4. Estructura del treball	10
4. Marc teòric	10
4.1. Revisió de la literatura del treball	10
4.2. Fonaments del trading algorítmic	12
4.3. Tecnologies i eines dels trading bots	14
4.4. Models de Machine Learning Aplicats al trading	14
4.4.1 Aplicacions del Machine Learning als mercats financers	15
4.4.2. Algoritmes de Machine Learning utilitzats en el trading	15
4.4.3. Beneficis del Machine Learning dins del trading	17
4.4.4. Desafiaments i limitacions del Machine Learning dins del trading	18
4.5. Com s'optimitzen els trading bots?	19
4.6. Regulació i consideracions ètiques	20
5.1. Disseny del marc pràctic	22
5.2. Inversor IA : El nostre propi trading bot	23
5.2.1 Elecció d'actiu i període de temps	23
5.2.2 Creació del trading bot	25
5.2.3. Anàlisi del codi de programació de Python:	25
5.2.4. Resultats del Trading bot	29
5.3. Inversor humà	32
5.3.2. Obtenció de dades	33
5.3.3. Resultats obtinguts	35
5.4.Comparació de resultats	36
6.Conclusions	38
7. Bibliografia / Webgrafia	40

1. Els trading bots: el futur del trading estratègic?

Català

Aquest projecte de recerca té com objectiu envoltar en un context general el fenomen modern dels “tradingbots”, un nou sistema d’elecció d’inversió impulsat per intel·ligència artificial.

En un context global on la velocitat i l’eficiència en la presa de decisions financeres són crucials, els tradingbots han esdevingut una eina imprescindible per als inversors i institucions. Aquests sistemes, basats en algorismes i sovint suportats per tecnologies com la intel·ligència artificial (IA) i el machine learning (ML), permeten automatitzar operacions borsàries amb un nivell d’eficàcia superior al de les estratègies manuals tradicionals. Els mercats financers són espais complexos que requereixen solucions innovadores per gestionar la creixent quantitat de dades i la seva velocitat de canvi.

Aquest treball analitza les bases teòriques, els components tècnics i els casos pràctics de l’empleament de trading bots, amb èmfasi en l’optimització i la gestió del risc. Així mateix, s’estudia la seva aplicació en diferents classes d’actius, com ara accions, divises i criptomonedes, destacant les estratègies més utilitzades, com l’arbitratge, el trading de tendències i l’anàlisi quantitativa.

Anglés

Trading bots, also known as automated trading systems, have revolutionized the way investors interact with financial markets. This paper analyzes the theoretical foundations, technical components, and practical cases of trading bot usage, with an emphasis on optimization and risk management. It also examines their application across different asset classes, such as stocks, currencies, and cryptocurrencies, highlighting the most commonly used strategies, including arbitrage, trend trading, and quantitative analysis.

In a global context where speed and efficiency in financial decision-making are crucial, trading bots have become an essential tool for investors and institutions. These systems, based on algorithms and often supported by technologies such as artificial intelligence (AI)

and machine learning (ML), enable the automation of stock market operations with a level of efficiency superior to that of traditional manual strategies. Financial markets are complex environments that require innovative solutions to manage the growing volume of data and its rapid pace of change.

Castellano

Los trading bots, también conocidos como sistemas automatizados de negociación, han revolucionado la forma en que los inversores interactúan con los mercados financieros. Este trabajo analiza los fundamentos teóricos, los componentes técnicos y los casos prácticos del uso de trading bots, con énfasis en la optimización y la gestión del riesgo. Asimismo, se estudia su aplicación en diferentes clases de activos, como acciones, divisas y criptomonedas, destacando las estrategias más utilizadas, como el arbitraje, el trading de tendencias y el análisis cuantitativo.

En un contexto global donde la velocidad y la eficiencia en la toma de decisiones financieras son cruciales, los trading bots se han convertido en una herramienta imprescindible para los inversores e instituciones. Estos sistemas, basados en algoritmos y con frecuencia respaldados por tecnologías como la inteligencia artificial (IA) y el machine learning (ML), permiten automatizar operaciones bursátiles con un nivel de eficacia superior al de las estrategias manuales tradicionales. Los mercados financieros son entornos complejos que requieren soluciones innovadoras para gestionar el creciente volumen de datos y su rápida evolución.

Este trabajo analiza los fundamentos teóricos, los componentes técnicos y los casos prácticos del uso de trading bots, con énfasis en la optimización y la gestión del riesgo. Asimismo, se estudia su aplicación en diferentes clases de activos, como acciones, divisas y criptomonedas, destacando las estrategias más utilizadas, como el arbitraje, el trading de tendencias y el análisis cuantitativo.

2. Presentació del projecte

2.1 Motivacions

En aquesta secció volem exposar els motius que ens han portat a escollir aquest tema per al nostre treball de fi de grau. Des de fa anys, fins i tot abans de conèixer-nos, ja compartíem un gran interès pels mercats financers. De manera autodidacta, investigàvem pel nostre compte sobre el món dels actius financers i les inversions, i aquesta curiositat ens va portar a voler aprofundir encara més en aquest àmbit. Amb l'objectiu de convertir la nostra passió en una futura trajectòria professional, vam decidir cursar el doble grau en ADE i Finances i Comptabilitat, amb la voluntat d'adquirir els coneixements necessaris per entendre i operar en aquest sector.

El nostre camí conjunt va començar el primer dia de classe del grau, ara fa gairebé quatre anys. Des d'aquell moment, vam compartir interessos, experiències i aprenentatges, coincidint en la nostra passió pel món financer. Aquest vincle ens ha portat a treballar plegats en diversos projectes i, finalment, a escollir aquest tema per al nostre TFG.

En concret, ens hem volgut centrar en els trading bots, ja que representen una de les tecnologies més innovadores i disruptives dins dels mercats financers. L'automatització de les operacions borsàries mitjançant algoritmes avançats permet augmentar l'eficiència, reduir l'error humà i aprofitar oportunitats de mercat en qüestió de mil·lisegons. No obstant això, el seu ús també planteja reptes com la volatilitat que poden generar i la regulació associada a aquest tipus de sistemes. A través d'aquest treball, volem analitzar les seves característiques i treure una conclusió sobre el seu ús.

2.2 Temporalització

Fins a la data actual, hem dedicat el nostre temps lliure a la recerca i recopilació d'informació relacionada amb el tema del nostre projecte, amb l'objectiu d'obtenir una base sòlida per al seu desenvolupament.

-Fases del projecte:

Recerca i recopilació d'informació (10/11/2024 - 10/12/2024)

- Investigació sobre els mercats financers i els trading bots.
- Anàlisi de bibliografia i estudis previs rellevants.
- Recopilació de dades per establir una base teòrica sòlida.

Desenvolupament del marc teòric (10/12/2024-20/02/2025)

- Estudi de les diferents estratègies de trading automatitzat i manual.
- Revisió de metodologies existents i tecnologies aplicades als trading bots.
- Elaboració del marc teòric que servirà de base per a la fase pràctica.

Disseny i implementació de les proves pràctiques (20/02/2025 – 1/05/2025)

- Implementació d'un trading bot amb una estratègia automatitzada definida.
- Execució d'operacions de trading manual per part d'un operador humà, seguint una metodologia estructurada.
- Establiment de paràmetres comuns per garantir una comparació objectiva (mercats, horaris, capital inicial, estratègies, etc.).

Anàlisi i comparació de resultats (1/05/2025 - 6/05/2025)

- Recopilació de dades sobre la rendibilitat, risc i consistència de cada sistema.
- Comparació dels resultats entre el trading bot i el trading humà per identificar avantatges i inconvenients de cada enfocament.
- Avaluació de l'efectivitat de l'automatització respecte a la presa de decisions humanes en els mercats financers.

Redacció final i presentació del TFG (6/05/2025 - 16/05/2025)

- Integració dels apartats teòric i pràctic en el document final.
- Revisió i correcció del treball per garantir la coherència i la qualitat del contingut.

-Preparació de la defensa del projecte seguint les directrius establertes per la URV.

3.Introducció

3.1. Rellevància del tema d'estudi

En el món en que vivim actualment, la gran majoria dels mercats financers funcionen en ambients altament digitalitzats, caracteritzats per un gran dinamisme i on els moviments del mercat són continus i frenètics. Dins d'aquest context, els trading bots han sorgit fa relativament poc temps com una eina clau pels agents que operen dins del món dels mercats financers. Aquests sistemes caracteritzats per l'automatització i pel seu funcionament basat en equacions algorítmiques avançades han vingut per canviar el món de la inversió tal com el coneixem, minimitzant l'actuació humana als mercats.

Si haguéssim d'aclarir quin és el factor que li dona importància a aquest tema com a nucli del nostre treball de recerca, hauríem de fer èmfasi en la capacitat dels trading bots d'adaptar-se a tant a la velocitat com al volum de les operacions que es donen avui dia en els mercats financers comuns. Vivim en un món totalment digitalitzat i amb una quantitat pràcticament infinita de dades disponibles, cosa que dificulta als inversors humans cada cop més poder mantenir-se al corrent de tots els fets i esdeveniments que influeixen en els moviments dels mercats, mentre que els trading bots resolen aquesta mancança gràcies al seu funcionament definit per models matemàtics i d'anàlisi avançats.

Aquests fets, donen una gran rellevància al tema de treball, ja que estem centrant la nostra recerca en una eina de inversió que té tant els recursos com el potencial necessaris per convertir-se en una eina imprescindible que, ja sigui dins d'un període curt o llarg de temps, podrien arribar a adoptar la gran majoria dels inversors sinó bé tots en un àmbit d'ús rutinari dins del món de les operacions financeres. És per això que, en aquest treball, estudiarem els seus avantatges i analitzarem per igual els riscos i inconvenients que té aquest tipus d'intel·ligència artificial.

3.2. Context general

Passem a contextualitzar el tema del nostre treball de recerca. Desde fa molts anys, el món de les finances i la inversió s'ha caracteritzat per tenir com a focus central la decisió humana. Les decisions a l'hora d'invertir i de com invertir sempre s'han vist afectades per una sèrie de biaixos i condicions exògenes a la simple i pura matemàtica que, depenent de molts factors, han pogut resultar avantatjoses a l'hora de prendre decisions correctes. D'altra banda, també hem pogut veure com aquestes condicions han desembocat, en certs moments de la història, en desastres financers causats principalment per factors psicològics com el pànic com va ocórrer en el crack del 29.

I tot i tenir la intel·ligència artificial tan present com a un concepte que es relaciona fàcilment amb l'àmbit dels trading bots, hem de dir que el principi va molt més enrere. Podem observar les primeres aproximacions a aquesta tecnologia en la dècada dels anys 80 per exemple, on trobem a personatges com l'aclamat "pare del trading sistemàtic" Richard Dochian, qui per primer cop va introduir un sistema automatitzat de trading basat en unes normes pre establertes que definien els moviments i operacions que s'executaven al mercat. També, durant la dècada dels 90, observem com comencen a aparèixer els primers bancs en fer servir sistemes basats en algorismes anomenats "sistemes de trading quantitatiu" que s'encarragaven d'executar ordres dins del mercat.

Si seguim avançant en el temps observem com, a la dècada dels 2000, la digitalització i el naixement i alçament d'Internet fan de camp de conreu pel naixement de trading bots més avançats que els sistemes algorítmics que havíem mencionat anteriorment i comencen a aparèixer els primers traders d'altra freqüència, que és com s'anomenava en l'època a aquells "bots" capaços d'executar milers d'ordres de mercat per segon.

I per fi arribem al present, un moment on la tecnologia segueix creixent i on últimament trobem un concepte que es troba com a tendència per la seva evolució, utilitat i facilitat d'accés per tots els públics: la intel·ligència artificial. Aquest concepte ha revolucionat l'àmbit dels trading bots aportant noves possibilitats que abans no haguéssim pogut imaginar. Avui dia podem trobar intel·ligències artificials dedicades al món de les inversions capaces d'analitzar i processar incontables quantitats de dades no només quantitativament, sinó que a més són capaces d'analitzar el sentiment del mercat en alguns casos a través de la recerca i investigació de notícies públiques. Tot això amb la possibilitat d'executar incontables ordres de mercat per segon per tal d'aconseguir els millors rendiments del

mercat i, afegidament, amb la capacitat donada d'aprendre de les operacions que fa a través de tecnologies com el "Machine Learning".

En conclusió, podem veure que el tema que tracta el nostre treball de recerca no apareix sobtadament, sinó que és una temàtica amb la que s'ha interaccionat desde fa gairebé 50 anys. El somni de molts inversors és prendre les millors decisions en cada moment per obtenir els majors rendiments possibles dins dels mercats. Fa mig segle aquesta idea hagués sigut tractada com una bogeria degut a les limitacions humanes en aquest àmbit, en canvi, avui, podem dir que estem una mica més aprop d'aconseguir-ho o, com a mínim, aproximar-nos a aquesta idea que fa somniar a tants inversors dins dels mercats financers.

3.3. Visió general del projecte i metodologia

Emprarem un enfocament experimental i comparatiu, amb l'objectiu principal de comparar el trading automatitzat amb el manual i la seva eficàcia en els mercats financers. Aquesta comparació es realitzarà mitjançant una plataforma de trading, que encara no s'ha definit.

Durant el període de pràctiques, s'establiran condicions comunes per a ambdues modalitats de trading, com el capital inicial, els actius a negociar, els horaris d'operació, entre altres variables. Un cop finalitzat el termini de pràctica, es tancaran totes les operacions que es trobin en curs i es procedirà a recopilar totes les dades obtingudes durant el procés.

Aquestes dades seran analitzades per determinar l'eficiència i el rendiment de cada sistema. L'objectiu final és avaluar la real eficiència d'un trading bot en comparació amb el rendiment d'un operador humà, analitzant factors com la rendibilitat, el risc, el temps de resposta i la consistència en les operacions.

3.4. Estructura del treball

Aquest treball s'organitza en diverses seccions que permeten abordar de manera progressiva i ordenada els diferents aspectes del projecte.

En primer lloc, trobarem una part teòrica, que es dedica a explorar en profunditat els conceptes fonamentals i les bases de l'àrea d'estudi. Aquesta secció ens proporciona els coneixements necessaris per entendre els aspectes clau del trading automatitzat i manual, així com els antecedents i les tendències actuals del sector. Aquesta part teòrica serveix com a fonament per poder desenvolupar una part pràctica robusta i ben informada. Un cop establerta la base teòrica, passarem a la fase pràctica, en la qual es portaran a terme les proves i experiments que permetran posar en pràctica els coneixements adquirits.

Finalment, s'exposaran les conclusions obtingudes a partir de l'anàlisi dels resultats, les quals proporcionaran una visió completa i rellevant sobre el tema d'estudi i una conclusió sobre l'ús d'aquesta tecnologia.

4. Marc teòric

4.1. Revisió de la literatura del treball

El trading a partir d'algoritmes ha sigut una revolució en els mercats financers durant les últimes dècades. Aquest enfocament a l'hora d'operar als mercats permet executar operacions a una gran velocitat i amb una precisió impossibles d'aconseguir pels operadors humans dels mercats financers. Dins d'aquest àmbit algorítmic, els trading bots han guanyat una gran rellevància en els últims anys gràcies a la evolució exponencial de les tecnologies basades en intel·ligència artificial que han fet evolucionar la manera en que els trading bots estudien i actuen basant-se en dades de caràcter històric, diferents patrons de conducta dins del mercat i avançats models basats en les matemàtiques modernes.

Com hem esmentat anteriorment, la introducció de la intel·ligència artificial ha marcat un abans i un després en aquests sistemes a través d'eines com el anteriorment explicat machine learning o el processament de llenguatge natural. Això d'entre més eines i sistemes han permès als bots desenvolupar capacitats d'adaptació als constants canvis del

mercat i han desembocat en noves i més sofisticades tècniques i estratègies de trading que poden maximitzar beneficis minimitzant els riscos que s'afronten a l'hora d'invertir, tot de manera totalment automatitzada.

Si fem mirada enrere i observem algunes investigacions sobre el tema, trobarem treballs com els de Treleaven, Galas i Lalchand (2013) que estudien l'evolució del trading algorítmic passant de simples estratègies d'arbitratge fins a avançats sistemes basats en la intel·ligència artificial. En aquesta mateixa línia, trobem investigadors com la experta en trading algorítmic i finances quantitatives Irene Aldridge que destaquen i fan èmfasi en com l'automatització de les operacions als mercats permeten optimitzar en gran mesura l'execució d'ordres per tal de poder disminuir els possibles impactes que té el mercat en els volums d'operacions més grans (Aldridge, I., 2013).

També, si seguim per la via de l'aprenentatge automàtic, podem trobar treballs com els de Zhang i Zohren, on es parla de com les xarxes paraneuronals arrel de les IAs han demostrat ser funcionals i eficaces a l'hora de predir les tendències que adopta el mercat, superant altres models tradicionals basats en l'estudi de sèries temporals. (Zhang & Zohren, 2020a).

Hauríem de mencionar no només els factors quantitius, sinó que també els psicològics. I es que trobem que els trading bots tenen una gran capacitat també per estudiar el llenguatge natural, que com veiem a estudis com els dels investigador Bollen, Mao i Zheng (2011), són un factor important a l'hora de predir les tendències de mercat. La capacitat dels trading bots per estudiar el sentiment del mercat ha sigut objecte d'estudi en els últims anys, i hem pogut veure estudis com els de Alejandro López-Lira i col·laboradors a la universitat de Florida (2023) on entrenen models de llenguatge d'intel·ligència artificial perquè puguin donar suport i consell als inversors a partir de l'anàlisi de notícies de diferents fonts que poden provocar canvis i fluctuacions al mercat degut a biaixos emocionals (López-Lira, A., & Tang, Y. 2023).

En conclusió, aquesta petita anàlisi literària que hem portat a fer prova de manera evident que la inclusió de les intel·ligències artificials en els trading bots han optimitzat i millorat en gran mesura les estratègies d'actuació als mercats, optimitzant tant l'adaptabilitat dels models com l'anàlisi de la informació que reben en forma d'inputs. No obstant, hem de tenir en compte que existeixen desafiaments relacionats amb com interpretem aquests models i de la seva estabilitat en entorns de mercat altament volàtils, la qual cosa és una font de possibles noves investigacions que portin a millorar aquest àmbit tan extens.

4.2. Fonaments del trading algorítmic

El trading algorítmic és una metodologia d'inversió en la qual un conjunt de regles predefinides per programació s'utilitzen per automatitzar el procés d'operar als mercats financers per a obtenir millors resultats. Aquestes regles es poden basar en diferents variables, com poden ser preus, volum, o fins i tot indicadors tècnics. Els algoritmes treballen en temps real per identificar oportunitats de negoci i executar les operacions de manera automàtica, sense necessitat del factor humà (Chan, 2013).

El funcionament dels sistemes algorítmics és possible gràcies a l'ús d'algoritmes matemàtics avançats i models estadístics que es basen en l'anàlisi d'un elevat volum de dades. Aquests sistemes poden prendre decisions a una velocitat molt més gran que la d'un operador humà, fet que els permet identificar oportunitats d'inversió en fraccions de segon.

En els últims anys, el trading algorítmic ha guanyat molta rellevància gràcies a l'evolució i importància de les tecnologies relacionades amb la intel·ligència artificial i l'aprenentatge automàtic (machine learning). Aquestes eines permeten als bots de trading millorar les seves estratègies d'inversió a mesura que s'adapten als canvis i fluctuacions del mercat. Així, els bots de trading poden identificar patrons històrics, analitzar sentiments del mercat o fins i tot utilitzar notícies per adaptar les seves estratègies d'inversió de manera eficient.

Un dels grans avantatges del trading algorítmic és la seva eficiència. Els algoritmes poden processar grans quantitats de dades i executar ordres en temps real de forma molt més ràpida i precisa que una persona. Això fa que les operacions siguin molt més efectives i minimitza els errors que podrien cometre els traders humans per qüestions de temps o d'emocions.

Un altre avantatge clau és l'eliminació del factor emocional. Quan un trader humà es veu davant de decisions d'inversió, sovint influeixen factors com l'ansietat, la por o l'eufòria. Els bots, en canvi, prenen decisions estrictament basades en dades objectives, reduint així el risc de fer moviments impulsius que podrien resultar en pèrdues importants del capital.

A més, els sistemes basats en intel·ligència artificial són capaços d'adaptar-se als canvis del mercat. Això vol dir que, a mesura que els algoritmes reben més informació, poden millorar continuament les seves prediccions i les seves decisions. Això fa que siguin més flexibles i capaços de respondre millor a les noves condicions del mercat.

Una altra gran avantatge és la reducció de costos operacionals. Els bots poden operar de manera automàtica les 24 hores del dia, sense necessitat d'estar pendents d'una supervisió constant.

El anàlisi del sentiment del mercat és un element cada vegada més important. A través de l'estudi de les emocions i opinions que es comparteixen a les xarxes socials, altres plataformes digitals i index com el "Fear and Greed Index" (analitzador de por i codícia), els algoritmes poden captar senyals de canvi de sentiment i anticipar-se a moviments del mercat, cosa que és molt útil per a la presa de decisions. (Zhang & Zohren,2020b)

Tot i que el trading algorítmic ofereix molts avantatges, també presenta alguns desavantatges importants. Un dels més destacats és que els algoritmes poden tenir dificultats quan els mercats experimenten volatilitat extrema o canvis sobtats. Els algoritmes estan dissenyats per seguir patró i tendències històriques, però quan el mercat es torna erràtic o pateix caigudes sobtades, poden no reaccionar de manera òptima. Això pot comportar pèrdues importants si no es tenen mecanismes de protecció adequats.

Aquest punt ens porta a una altra desavantatge, la necessitat de supervisió constant. Tot i que els bots poden operar de manera autònoma, és fonamental tenir sistemes de protecció per garantir que els algoritmes no facin moviments perillosos en moments d'incertesa del mercat. Per tant, encara que els bots siguin molt eficaços, s'ha de supervisar que tot estigui funcionant correctament.

Un altre desavantatge és que, com els mercats financers estan en constant canvi, els algoritmes necessiten actualitzacions i ajustos continus per adaptar-se a les noves condicions. Si els algoritmes no s'actualitzen adequadament, poden quedar obsolets i no ser capaços de fer front a situacions imprevistes, la qual cosa pot afectar la seva eficàcia.

La dependència de la tecnologia també és un repte. Si es produeixen fallades tècniques, errors de programació o problemes de connexió, els bots podrien fallar a l'hora de realitzar operacions, provocant pèrdues o afectant la rendibilitat de les estratègies.

4.3. Tecnologies i eines dels trading bots

Per tal de desenvolupar la nostra intel·ligència artificial orientada al trading automatitzat, hem fet servir un conjunt de tecnologies específiques que ens han permès implementar, provar i analitzar l'eficiència del nostre sistema.

Hem escollit Python com a llenguatge principal per programar el nostre trading bot. Python és un dels llenguatges més utilitzats en l'àmbit del trading algorítmic degut a la seva senzillesa, llegibilitat i gran quantitat de biblioteques especialitzades per a l'anàlisi de dades, finances i intel·ligència artificial. A més, moltes plataformes de trading automatitzat ofereixen compatibilitat directa amb aquest llenguatge, fet que facilita enormement el desenvolupament i testatge de sistemes.

La plataforma escollida per al desenvolupament i simulació del nostre bot ha estat QuantConnect, un entorn de codi obert que permet crear estratègies de trading mitjançant Python i QuantConnect.

Tot i que gran part del treball s'ha realitzat directament des de QuantConnect, també hem utilitzat recursos de formació (com documentació oficial, tutorials i fòrums) i eines de suport com Google Colab per practicar i provar fragments de codi. A més, hem consultat bibliografia específica relacionada amb l'ús de Python per al trading algorítmic, com per exemple "Deep Learning with Python" de Chollet o "Machine Learning for Asset Managers" de Marcos López de Prado.

4.4. Models de Machine Learning Aplicats al trading

El Machine Learning (aprenentatge de la màquina), és un sistema basat en intel·ligència artificial que ha estat una revolució en el món financer gràcies a que ha permès crear models de predicció capaços de detectar diferents patrons i tendències repetides dins del món dels mercats financers. El seu principal avantatge davant de la estadística clàssica radica en el fet que pot treballar amb volums inconmensurables de dades en temps real i fer la quantitat d'ajustaments necessaris per adaptar-se a la nova informació processada, cosa que ha causat que aquest sistema hagi esdevingut la principal eina dins de l'àmbit de les operacions automatitzades amb intel·ligència artificial en els mercats financers.

4.4.1 Aplicacions del Machine Learning als mercats financers

A continuació, analitzarem algunes de les aplicacions més destacables d'aquesta tecnologia dins del camp dels mercats financers:

Anàlisi de riscos

Gràcies a l'anàlisi continuat d'informació que fan aquests sistemes amb totes les dades que registren en temps real, el machine learning permet calcular aproximacions en quant a les probabilitats de que es compleixin certes corrents dins dels mercats per tal d'escollir les estratègies més òptimes a l'hora d'operar.

Gestió de carteres

El machine learning pot, a partir de la seva anàlisi de mercats a nivell històric i en temps real, dissenyar de manera automàtica carteres a partir d'algoritmes que funcionen de manera similar a xarxes neuronals que optimitzen al màxim la ponderació de carteres intentant escollir els millors actius en base al seu estudi de dades.

Predicció de preus

Com en altres aplicacions mencionades anteriorment, l'estudi i anàlisi de dades històriques i en temps real permet que el machine learning sigui una eina idònea per tal de predir els moviments del mercat i els preus futurs que poden adoptar els actius financers amb els que s'opera.

High-Frequency Trading (HFT)

El High-Frequency Trading es refereix a un dels avantatges principals que tenen les intel·ligències artificials davant dels inversors humans, que radica en el fet de poder prendre decisions i executar ordres de compra i venda en qüestió de mil·lèsimes de segon, cosa que permet efectuar un gran volum d'operacions per poder adaptar-se i reaccionar als moviments del mercat de la manera més ràpida possible (Narang, R. K.,2009).

4.4.2. Algoritmes de Machine Learning utilitzats en el trading

Com hem mencionat en altres seccions d'aquest treball, les intel·ligències artificials de trading funcionen a través de diferents algoritmes. En el cas de la tecnologia Machine-Learning, això no canvia i trobem diferents algoritmes sota els quals treballa aquesta tecnologia per oferir els millors resultats possibles. A continuació, analitzarem

alguns dels més destacables de manera breu per poder obtenir algunes nocions del seu funcionament i ús.

Algoritmes de regressió lineal i logística

Comencem amb un dels tipus d'algoritmes més bàsics que trobem amb el Machine Learning. Els algoritmes de regressió lineal tenen com a objectiu buscar la relació entre el preu d'un actiu financer i diferents variables externes per tal de poder fer millors prediccions basades en fets que han succeït anteriorment.

No obstant, també podem trobar la regressió logística, que s'utilitza per definir si el moviment que farà el preu serà de pujada o baixada en funció de diferents variables i factors fundamentals del mercat.

Xarxes neuronals artificials (ANNs)

Aquest tipus d'algoritme és molt interessant ja que té com objectiu tancar la distància entre humans i màquines per tal de poder aconseguir una millor perspectiva de la psicologia humana a l'hora de definir operacions i moviments al mercat. Les ANNs intenten imitar la ment humana a l'hora de decidir com invertir, de manera que deixa de limitar la tecnologia simplement a la estadística i l'anàlisi quantitatiu (Goodfellow, Bengio, & Courville, 2016).

D'aquesta manera, poden analitzar el sentiment del mercat i no simplement els números i xifres pels quals es mouen els mercats financers, cosa que influeix enormement en els moviments que succeeixen en aquest món.

Random Forests & XGBoost

Aquest sistema algorítmic es basa en la creació de múltiples decisions agrupades de manera ramificada (d'aquí el nom de forest), de manera que es creen "arbres" de decisions on l'objectiu és el rebutjament de les pitjors decisions per obtenir la millor i més estable ramificació de totes.

XGBoost vindria a ser una versió millor d'aquesta tecnologia que utilitza la tecnologia del boosting. El boosting és una tecnologia que, en aquest cas, combina múltiples models més primaris com els arbres de decisió que hem mencionat anteriorment per crear un model més sofisticat. Aquesta tecnologia funciona de manera seqüencial, això significa que cada model que surt intenta corregir imperfeccions i defectes de l'anterior model, així de manera consecutiva fins assolir un model de decisió òptim on figurin les decisions més lògiques per

assolir resultats estables i òptims dins dels mercats (James, Witten, Hastie, & Tibshirani, 2021).

Aprenentatge per reforçament (Reinforcement learning)

Aquest sistema algorítmic és un dels més comuns en l'àmbit del Machine Learning. És el simplement de deixar que una intel·ligència artificial aprengui a través de recompenses o penalitzacions. En aquest cas, per la IA, la recompensa vindria a ser aconseguir rendibilitats positives i aconseguir guanys i la penalització vindria a ser no aconseguir això.

Tenint en compte això, l'algoritme s'encarrega de, poc a poc, acumular experiència per detectar quines són les decisions que desemboquen en una recompensa i quines en una penalització.

Posem un exemple per entendre això. Si tenim una IA que opera en el món de les accions, al principi executarà ordres de compra i de venda amb poca precisió i possiblement no tindrà massa èxit al començament. No obstant, amb el temps, aquesta aprendrà que vendre quan els preus estan pujant i apropant-se a límits i comprar quan els preus baixen i s'acosten a resistències del mercat li ajudarà a aconseguir millor rendibilitats al mercat. En conclusió, la IA aprendrà això i ho aplicarà en les seves operacions futures juntament amb una sèrie d'altres condicions i premises que ajuden a apropar-se a models d'inversió cada cop més sofisticats i avançats.

4.4.3. Beneficis del Machine Learning dins del trading

Procedim a comentar els principals avantatges d'aquesta tecnologia de cara al trading algorítmic

Presa de decisions

En aquest context podem comentar que el Machine Learning és un dels motors principals que permeten a les eines de trading artificial reaccionar de manera ràpida i eficient als estímuls i moviments que es donen dins dels mercats.

Reducció del biaix humà

És ben sapigut per la majoria d'inversors que un dels majors perills per les nostres inversions som nosaltres mateixos. La nostra naturalesa com a humans provoca que moltes de les nostres decisions es vegin afectades per l'anàlisi subjectiu que fem dels estímuls que obtenim de l'exterior a través de la nostra pròpia xarxa neuronal que molts cops es veu

afectada i sugestionada per factors que hem viscut al llarg de les nostres vides. En aquest aspecte, el Machine Learning té l'avantatge de poder analitzar aquestes circumstàncies de manera objectiva, minimitzant l'error que es dona a causa de les emocions en el món dels mercats.

Optimització continuada

Com hem vist anteriorment, molts algoritmes de machine learning funcionen en temps real, el que permet a les IA adaptar-se constantment i millorar els seus processos per tal d'aportar millors resultats.

4.4.4. Desafiaments i limitacions del Machine Learning dins del trading

Tot i tenir molts avantatges i ser molt útil, el Machine Learning també enfronta alguns desafiaments i limitacions que fa falta esmentar.

Sobreajustament de models:

Per sobreajustament, ens referim al fet que cap la possibilitat de que alguns models d'IA s'adaptin massa a dades passades i no puguin generalitzar bé una manera d'actuar en condicions futures. En aquest cas, la intel·ligència artificial tindria una gran capacitat de definir els moviments del mercat si el mercat funcionés de la mateixa manera en que ho feia quan la IA va aprendre d'aquests moviments, cosa que provocaria que tingui menys precisió a l'hora de preveure els moviments que faci el mercat en el futur en cas de no actuar de la mateixa manera, cosa que és molt possible i habitual en el món financer actual (López de Prado, 2018).

Dependència de informació de qualitat

Aquesta limitació és important de tenir en compte. Al igual que a una persona, la informació que utilitzem per educar i entrenar una intel·ligència artificial és molt important, ja que dependrà d'aquesta informació els seus moviments i prediccions futures. Per tant, sempre hem d'intentar procurar que les IAs que fem servir ja siguin d'inversió o en altres àmbits hagin sigut entrenades amb informació de bona qualitat.

Events inesperats

Això és una limitació que podríem dir que, tot i afectar tant a persones com a IAs, és una limitació ja que una IA no pot preveure un esdeveniment sobtat com un desastre natural, l'explosió d'una bombolla especulativa, etc...

Costos de manteniment i computació

Tenir els models predictius i operatius més eficients té grans costos darrere per mantenir-los actius, a més del fet que requereixen de altíssimes capacitats de processament d'informació. Són models costosos pels inversors que decideixen desenvolupar-los.

Finalment, podem afirmar que el Machine Learning és un dels factors claus del desenvolupament de la IA en el món financer. Aporta una gran sèrie d'eines que proporcionen molts avantatges a l'hora d'analitzar els mercats per poder operar en ells. No obstant, hem de mencionar que la seva implementació no és senzilla i fa falta una preparació rigurosa i estricta per posar en funció aquests sistemes tant sofisticats i que operin de manera correcta en els entorns financers als que fem front a dia d'avui, on el canvi està a la ordre del dia.

4.5. Com s'optimitzen els trading bots?

El procés de millora i optimització d'un bot destinat a la inversió és un procediment rigorós que ajuda a que la IA millori el seu rendiment i la manera que té de predir i operar dins del mercat a partir de continus ajustaments en els seus paràmetres algorítmics. De certa manera podríem dir que les IAs es poden "entrenar" per tal que puguin aconseguir millors resultats en qualsevol àmbit, i el món dels mercats financers no és cap excepció a aquesta norma.(Goodfellow et al., 2016).

El primer pas preparatori seria escollir les dades que serveixen com *inputs* per donar informació al model per tal de poder raonar i operar. En el cas dels mercats financers, podríem parlar de dades com preus històrics i altres indicadors que donin informació sobre com es comporta el mercat i dels rendiments que es poden esperar depenent de les seves fluctuacions. D'aquesta manera eliminem els resultats extrems que pot treure una IA, ja que aquestes es mouen principalment a través dels números i la estadística per operar (Brownlee, 2017).

D'aquesta manera, podem afirmar que una intel·ligència artificial té la qualitat dels *inputs* que rep per treballar, és per això que és crucial treballar sempre amb dades de qualitat que puguin representar de manera fidel i realista l'entorn financer en el que volem que s'operi.

Un cop s'han introduït aquestes dades, és qüestió d'avaluar els resultats del model de manera que escollim unes mètriques adequades per tal de veure si està tenint resultats adequats a les nostres expectatives. En l'entorn del mercat podríem trobar indicadors útils com la ràtio de Sharpe o la rendibilitat obtinguda entre altres. Amb aquests resultats podem orientar l'entrenament de la nostra IA depenent dels objectius a establir ja que, per exemple podem trobar que un bot està obtenint bons resultats, però a costa d'una gran exposició al risc dins d'un mercat. En aquest cas podríem orientar l'entrenament de la nostra IA a fer moviments i operatives que l'exposin menys al risc del mercat en que opera. De la mà d'establir un objectiu, també hem d'establir una recompensa o "reward" que sigui el resultat d'establir el nostre objectiu. Fent servir l'exemple que hem mencionat anteriorment, el "reward" d'entrenar el nostre bot amb l'objectiu de tenir una menor exposició al risc en el mercat podria ser un flux de resultats positius més constants i una reducció en la variança dels seus resultats que ens permeti poder predir millor els possibles "outcomes" de l'estratègia que segueix. (Chan, 2013)

Finalment, només faria falta passar per un procés que ens sigui d'utilitat per validar les accions de la nostra IA. Aquí entra una de les dinàmiques més utilitzades en aquest món: el backtesting. En aquest cas, fem servir dades històriques per tal de posar la nostra IA dins d'un entorn totalment realista basat en el passat, de manera que podríem, per exemple, comprovar com hagués performat la nostra IA en períodes de temps passats com durant l'any 2021 per tal de veure com hagués actuat si haguéssim començat a operar amb ella en aquell període. D'aquesta manera obtenim resultats realistes que ens permeten validar els nostres resultats i, de manera inductiva, decidir si el nostre bot està preparat pel futur dels mercats. (Brownlee, 2017).

4.6. Regulació i consideracions ètiques

Espanya presenta un marc legal en constant evolució pel que fa a la inversió en criptodivises si es compara amb altres països que ja disposen d'una regulació més clara. Tot i això, ja existeixen determinats aspectes legals que cal tenir en compte, com són els següents:

Primer de tot cal saber que des de l'any 2021 el Banc d'Espanya exigeix el registre oficial dels proveïdors de serveis de canvi de criptodivises i de custòdia de moneders digitals

(exchanges). Aquesta mesura té com a objectiu garantir el compliment de la normativa sobre la prevenció del blanqueig de capitals i el finançament del terrorisme. Aquest registre comporta la identificació dels clients i el seguiment de les seves operacions, ja que el sector de les criptodivises ha estat utilitzat en repetides ocasions per finançar activitats delictives, aprofitant la seva combinació d'aparent transparència i anonimat en els darrers anys.

Des de finals de 2024 és vigent el Reglament MiCA (Markets in Crypto-Assets), estableix un marc legal comú en el context europeu. L'objectiu de MiCA és dotar el sector de major seguretat jurídica i garantir la protecció tant dels consumidors com dels proveïdors. Entre les seves principals exigències podem observar la transparència, el registre obligatori i la verificació de la identitat dels usuaris. Actualment, la majoria d'exchanges implementen mesures de seguretat com la doble o triple autenticació en determinades operacions, a més del registre previ mitjançant la identificació personal, com pot ser a partir del DNI de l'usuari.

Des d'un punt de vista ètic, és fonamental assegurar que el bot no contribueixi, ni de manera directa ni indirecta, a pràctiques com la manipulació de mercat, especialment en entorns amb baixa regulació. Aquest tipus de conductes, a més de ser èticament reprovables, poden comportar conseqüències legals i sancions econòmiques.

També cal tenir present aspectes clau com la ciberseguretat i la protecció de la informació confidencial. Si el sistema accedeix a fons o a claus privades, ha d'estar adequadament protegit contra possibles accessos no autoritzats. Qualsevol vulnerabilitat en aquest sentit pot derivar en responsabilitats legals directes per part dels desenvolupadors o responsables del sistema.

Per tant la resposta que trobem pel nostre projecte és que un bot de trading que operi exclusivament a títol personal no està obligat a registrar-se segons la normativa vigent. No obstant això, si s'ofereix com a servei comercial o a tercers, pot considerar-se una activitat financera regulada, sotmesa a supervisió segons el Reglament MiCA.

5 . Marc pràctic

Durant el desenvolupament de la part teòrica d'aquest treball, hem pogut observar que les intel·ligències artificials envers la inversió són una eina que porta en un camp de cultiu molts anys. Han passat per molts processos de modernització i optimització per arribar a ser el que són avui dia i, ara mateix, podríem dir que són una eina que desperta un gran interès en els inversors i que, cada cop més, veiem de manera més freqüent no només en la literatura sinó que també en camps d'ús pràctic.

A continuació, farem servir tot el coneixement teòric i conceptual que hem obtingut durant el desenvolupament d'aquesta part teòrica per tal de portar a desenvolupar el marc pràctic del nostre projecte i poder extreure més conclusions que ens ajudin a definir una resposta a la incògnita principal que planteja el nostre treball de recerca, que tracta sobre les expectatives sobre el futur d'aquestes eines d'inversió i el lloc que ocuparan al mercat durant els pròxims anys.

Procedim, després de tot això, amb el nostre experiment que trobarem explicat a continuació.

5.1. Disseny del marc pràctic

En la part pràctica del nostre projecte de recerca, volíem posar en manifest tots els coneixements que hem obtingut d'una manera que reflexi directament la utilitat i les projeccions a futur que pot tenir l'ús de les intel·ligències artificials en el món dels mercats financers.

Després d'una pluja d'idees on van caure idees relacionades amb entrevistes i enquestes, vam decidir fer un descartament de totes aquestes pràctiques usuals en aquest tipus de treballs i vam decidir optar per una opció diferencial que pensàvem que seria més original i divertida d'elaborar.

D'aquesta manera, neix la idea a través de la qual es desenvolupa aquest projecte: la comparació de resultats entre una intel·ligència artificial i un inversor humà per tal de veure quin dels dos performa millor en un determinat mercat i en un determinat període de temps.

5.2. Inversor IA : El nostre propi trading bot

Aquí radica la major part del treball que ha esdevingut la part pràctica d'aquest treball. Al principi vam considerar la idea de simplement analitzar les estadístiques d'alguna eina d'intel·ligència artificial fent servir internet com a font de dades per tal d'obtenir una informació ràpida.

No obstant, aquesta idea presentava dos principals inconvenients. El primer radica en el fet que aconseguir aquest tipus de dades és complicat sense fer un pagament (bastant alt) previ per tal que les persones que tenen la propietat intel·lectual d'aquests traders artificials ens proporcionin els seus resultats en la inversió. El segon principal inconvenient era que, tot i que hi hagués una petita possibilitat de que cap usuari ens pogués proporcionar aquest tipus d'informació, seria molt complicat que fos amb el nivell d'especificitat que nosaltres buscàvem a nivell de períodes de temps i actius a invertir.

Davant d'aquests obstacles, vam decidir prendre un pas endavant i investigar sobre com és el procés de creació d'una intel·ligència artificial que operi en un mercat. Després de moltes hores de formació a través de diferents fonts virtuals, vam culminar els nostres esforços amb la creació del nostre propi trading bot. A continuació, farem una anàlisi del procés de creació d'aquest trader algorítmic que vam dissenyar.

5.2.1 Elecció d'actiu i període de temps

Les primeres passes per crear una intel·ligència artificial que operi en qualsevol tipus de mercat, amb l'objectiu d'analitzar els seus resultats, és definir de manera molt clara l'actiu i el període de temps en que operarà, ja que volem aconseguir dades fiables.

Comencem per parlar de l'actiu escollit per invertir. En el nostre cas, i després de veure les possibles opcions que teníem al nostre abast, vam decidir que una de les millors opcions que teníem per desenvolupar el nostre experiment era amb la popular criptomoneda de Bitcoin (BTC) expressat el seu valor en dòlars americans (USD). Per poder explicar correctament el motiu de la nostra elecció, és millor que veiem abans perquè vam descartar altres opcions. En primer lloc vam plantejar la idea de desenvolupar aquest experiment a través de mercats més propis del nostre país com podria ser l'IBEX35, que com ja sabem, és un índex bursari que combina les 35 empreses més cotitzades a la borsa d'Espanya. No

obstant, vam descartar ràpidament aquesta idea i la de fer servir qualsevol altre tipus d'índex bursari ja que la majoria d'inversions en aquest tipus de fons són habitualment en terminis molt llargs, cosa que trobàvem poc adequada pel nostre experiment ja que consideràvem que seria més interessant fer servir un mercat més volàtil, on hi hagués una major quantitat de moviment dins del mercat per tal de veure com el nostre trading bot performava en un mercat on s'han de fer moltes operacions i on un inversor humà ha d'estar constantment alerta del que passa. Amb aquesta idea, juntament amb la majoria de la renda fixa i actius poc volàtils, vam passar a la idea dels futurs. La nostra principal problemàtica amb els futurs no radicava en la seva estructura dinàmica dins dels mercats on operen, ja que aquesta característica era apropiada per portar a fer el nostre experiment. El principal inconvenient venia del fet que molts d'aquests mercats no es trobaven disponibles dins de les opcions que donava el nostre trading bot per operar (cosa que veurem de manera més detallada en següents apartats quan parlem de l'estructura i l'elaboració de la IA). Amb tot això, finalment vam decidir que un dels actius més idonis per poder conduir el nostre experiment no només per la manera en que es mou dins del mercat, sinó també pel fet que la nostra plataforma de creació donava grans facilitats per poder analitzar els moviments del nostre bot, era efectivament Bitcoin.

Passem a parlar del període de temps comprés pel nostre experiment. Per tal que els nostres resultats no estiguessin compresos en un lapsus de temps massa petit, vam decidir operar amb una funció molt útil que ofereixen la majoria de plataformes de trading: El Backtesting. El Backtesting consisteix en una pràctica on els inversors poden operar de manera experimental en moments del mercat anteriors a l'actual per tal de testar les seves estratègies i així poder recopilar dades que els ajudin a definir si aquestes estratègies podrien ser útils per operar en el mercat actual. Nosaltres vam decidir fer aquesta pràctica per tal de poder aconseguir operar amb un període de temps de 5 anys, que compren desde inicis de 2019 fins a inicis de 2024. Vam decidir aquest període de temps ja que es situava en un matís apropiat entre els extrems de la inversió a curt termini frenètica que presenten alguns actius (ja que Bitcoin presenta una mica més d'estabilitat dins del mercat que la majoria de criptomonedes que hi cotitzen) i entre l'extrem de les inversions a molt llarg termini destinades a crear riqueses futures en grans períodes de temps.

Amb aquestes dues principals variables definides, era el moment de posar-se mans a la obra i dissenyar el nostre Trading Bot ideal per poder intentar superar els resultats d'un inversor humà.

5.2.2 Creació del trading bot

El procés de creació d'una intel·ligència artificial és sumament tediós i difícil si es vol portar a un nivell professional. Hi ha una infinitud de paràmetres que es poden tenir en compte a l'hora del disseny i la programació, cosa que pot fer el procés molt complex. No obstant, abans d'entrar en aquest tipus de detalls, primer veiem la plataforma que vam fer servir per portar a fer el nostre experiment.

Per tal de poder incloure el nostre codi de programació (del qual parlarem més endavant amb detall), necessitàvem d'una plataforma de trading que admetés funcions de programació i backtesting. Després de fer una recerca de les nostres diferents opcions, vam decidir fer servir la plataforma de QuantConnect, que permet programar bots de trading a través del llenguatge de programació de Python per tal de poder operar i, a més, realitzar backtesting per tal de veure com la nostra intel·ligència artificial performa al mercat. Era una eina ideal per desenvolupar l'experiment així que vam llençar-nos de cap amb aquesta opció per elaborar la nostra pràctica.

5.2.3. Anàlisi del codi de programació de Python:

Abans de veure el codi de programació que vam fer servir per dissenyar el nostre propi trading bot, hem de destacar un factor important a tenir en compte. Principalment, hem de destacar que, tot i que per sort tenim petites nocions de programació que ens van ajudar a desenvolupar aquest projecte, la nostra intel·ligència artificial està regida amb paràmetres molt simples com podem veure a continuació ja que el nostre nivell de coneixements en aquest àmbit no era tan gran com per poder afegir una gran quantitat de paràmetres a tenir en compte. No obstant, tot i la simplicitat del model que vam dissenyar, segueix sent igual d'útil per tal de poder-nos fer una idea de que tan avançats són aquests sistemes i del que poden arribar a aportar en un mercat com l'escollit per aquest experiment.

En conclusió, aquest model és només una aproximació al potencial que presenta la intel·ligència artificial en la inversió, i els seus resultats no haurien de ser interpretats com una realitat absoluta que assenya-li que totes les IAs han de seguir la mateixa corrent que el nostre model, ja que, òbviament, això dependrà del model programat en cada cas i de quins paràmetres es decideix tenir en compte per tal que aquest funcioni.

Ara sí, fem una ullada al nostre model de programació:

```
from AlgorithmImports import *

class RSITradingBot(QCAlgorithm):

    def Initialize(self):
        self.SetStartDate(2019, 1, 1)
        self.SetEndDate(2024, 1, 1)
        self.SetCash(100000)

        self.symbol = self.AddCrypto("BTCUSD", Resolution.Daily, Market.GDAX).Symbol

        self.rsi = self.RSI(self.symbol, 14, MovingAverageType.Wilders, Resolution.Daily)
        self.lastAction = None

    def OnData(self, data):
        if not self.rsi.IsReady:
            return

        current_rsi = self.rsi.Current.Value

        if current_rsi < 30 and self.lastAction != "BUY":
            self.SetHoldings(self.symbol, 1)
            self.lastAction = "BUY"

        elif current_rsi > 70 and self.lastAction != "SELL":
            self.Liquidate(self.symbol)
            self.lastAction = "SELL"
```

Amb un primer cop d'ull, seria difícil entendre tot el que veiem aquí reflectit, així que, a continuació, anirem explicant cada paràmetre de manera clara i entenedora perquè es pugui entendre el funcionament del nostre trading bot.

En primer lloc tenim la definició del període de temps amb el que volem que el nostre trading bot operi juntament amb el capital inicial a invertir.

```
def Initialize(self):  
    self.SetStartDate(2019, 1, 1)  
    self.SetEndDate(2024, 1, 1)  
    self.SetCash(100000)
```

Com podem veure, simplement havíem de definir que volíem que l'experiment de backtesting es conduís des de l'any 2019 fins a l'any 2024 amb un capital inicial constituït per 100.000 dòlars en aquest cas ja que estem treballant amb el mercat de BTC amb el seu valor traduït/expressat en dòlars.

Seguidament, trobaríem la definició del mercat i l'actiu en el que volem que inverteixi la nostra intel·ligència artificial i quins períodes de tancament ha de prendre el nostre bot com a referència dins del mercat per operar i obtenir informació.

```
self.symbol = self.AddCrypto("BTCUSD", Resolution.Daily, Market.GDAX).Symbol
```

En aquest cas, indiquem que volem que inverteixi en Bitcoin expressat en dòlars dins del mercat de GDAX (que vindria a ser part de la plataforma d'inversió de criptomonedes online coneguda com Coinbase). En quant als tancaments, vam establir que la nostra IA agafés dades amb els preus de tancament diari ja que així podria obtenir un major input de dades amb les quals treballar i, d'aquesta manera, tenir més informació a la seva disposició per tal de fer els seus moviments i decisions a dins del mercat.

A continuació, hem de veure de manera més extensa el següent component del nostre codi de Python ja que constitueix el factor principal que tindrà el nostre bot en compte per tal de prendre decisions.

Estem parlant del RSI (Relative Strength Index). Aquest indicador és un dels més importants i fets servir (per no dir el que més) en el disseny i programació de trading bots en el món financer. El RSI és un indicador que porta donant voltes pel món de les finances i el trading algorítmic desde la dècada dels 80, quan es van començar a dissenyar els primers models de trading basat en algorismes. La seva funció principal és mesurar que tan fort o dèbil és un actiu dins d'un mercat utilitzant com punt de referència els canvis de preu més recents a identificar per part de l'actiu, de manera que ajuda a identificar quan un actiu està

sobrevalorat o infravalorat. El més habitual és expressar aquest indicador amb valors que oscil·len entre 0 i 100, on els valors més alts assenyalen que un actiu està sobrevalorat (normalment valors per damunt de 70) i, els valors més baixos, assenyalen que l'actiu està infravalorat dins del mercat (valors per sota de 30 habitualment).

Ara que ja sabem més del RSI, analitzem la part primordial del nostre codi en la que es basa principalment el nostre model d'intel·ligència artificial per tal de prendre les seves decisions en el mercat:

```
self.rsi = self.RSI(self.symbol, 14, MovingAverageType.Wilders, Resolution.Daily)
```

En primer lloc trobaríem aquest línia de codi que assenya-la que la nostra intel·ligència artificial calcula un valor per l'indicador basant-se en la mitjana de Wilders dels preus de tancament cada 14 dies. El motiu pel qual fem servir la mitjana de Wilders és per tal de suavitzar els valors que pren la mitjana i així evitar valors extrems en els càlculs que puguin empenyar al nostre bot a prendre decisions abruptes a l'hora de realitzar ordres de compra o venda de l'actiu amb el que opera. Escollim 14 dies com a referència ja que el propi creador de la mitjana de Wilders, J Welles Wilder proposa a la seva obra "*New Concepts in Technical Trading Systems*" (1978) que aquest període de temps és idoni ja que troba l'equilibri en la sensibilitat i fiabilitat del mercat i evita valors extrems en el càlcul al disminuir el "noise" del curt termini, que presentaria, segons la seva obra, com un obstacle per reaccionar a temps als canvis del mercat.

A continuació trobaríem aquest senzilla línia de codi:

```
self.lastAction = None
```

L'objectiu d'aquest paràmetre és simplement identificar quina va ser l'última ordre que el nostre bot va executar per tal d'evitar que entri en un bucle de repetir constantment certes ordres al trobar-se en un moment d'estabilitat en el mercat.

Ara entrem en la part important que té en compte el nostre trading bot per prendre les seves decisions. Comencem amb les decisions de compra:

```
if current_rsi < 30 and self.lastAction != "BUY":  
    self.SetHoldings(self.symbol, 1)  
    self.lastAction = "BUY"
```

El que podem veure en aquesta part del nostre codi de Python, és que, quan el valor calculat del RSI sigui inferior a 30, la nostra IA executarà una ordre de compra amb el 100% del seu capital disponible per tal d'aprofitar un moment on l'actiu es troba infravalorat en termes d'interpretació de l'indicador RSI. Tot i que executar ordres amb el 100% del capital disponible sembli un moviment massa arriscat, vam prendre la decisió de fer que la nostra IA treballés d'aquesta manera per dos motius principals. El primer vindria a ser el fet que, els nostres limitats coneixements de programació ens van fer molt complicada la tasca d'intentar donar joc amb les proporcions del capital total amb les que el nostre bot operava. Aquest primer motiu anava de la mà amb el segon, que radica en el fet que volíem reflectir de manera simple i extrema com treballava un trading bot en l'ambient d'un mercat financer volàtil, i que millor manera d'expressar això que fent que adopti moviments arriscats en un entorn tan volàtil com és el de les criptomonedes per tal de poder valorar posteriorment que tan encertades han estat les seves decisions durant aquesta prova de backtesting que cobreix els últims 5 anys.

A continuació veiem que té en compte el nostre trading bot per tal d'efectuar les seves operacions de venda dins del mercat:

```
elif current_rsi > 70 and self.lastAction != "SELL":  
    self.Liquidate(self.symbol)  
    self.lastAction = "SELL"
```

En aquest cas, li donem la instrucció a la nostra IA per tal que realitzi operacions de venda quan el valor del RSI assoleixi valors per damunt de 70, cosa que assenya-la una possible sobrevaloració de l'actiu amb el qual s'esta operant. En aquest cas, la línia de codi que definia la operativa amb les ordres de compra estava inclosa amb aquesta, de tal manera que, en aquest cas, també realitzem ordres de venda amb la totalitat del capital. D'aquesta manera, veiem de manera més extrema tant els moviments que provoquen pèrdues en la nostra operativa com aquells que aconseguen guanyos.

5.2.4. Resultats del Trading bot

Per començar, farem una revisió dels resultats generals i alguns indicadors útils per poder avaluar els resultats de la nostra IA d'inversió i, després, farem una anàlisi més detallada de

com va actuar en determinats moments del mercat al llarg d'aquesta prova de backtesting que cobreix un període de 5 anys (2019-2024).

Parlem primer del rendiment brut i la rendibilitat. Com vam mencionar a la secció del treball on descríviem l'experiment, el capital inicial amb el que treballava el nostre bot era de 100.000 dòlars. Partint d'aquest punt i com podrem veure més endavant en el gràfic adjunt, el nostre trading bot va treure rendiments bruts per valor de 54.900,05 dòlars. Aquest rendiment expressat en termes percentuals suposaria que la nostra IA d'inversió va obtenir un 54,90005% de rendibilitat en el plaç de 5 anys estipulat. D'aquí podríem concloure que l'experiment ja ha complert un dels seus objectius, que era crear un trading bot que pogués treure bons rendiments dins del mercat.

No obstant, tot i veure aquest primer resultat que ens podria fer pensar que la nostra IA ha obtingut bons resultats en les seves operacions, hem d'analitzar altres variables que ens faran veure que no tot és tan perfecte com sembla. En aquest cas, QuantConnect ens ofereix la oportunitat de poder comprovar la ràtio de Sharpe que havia extret la nostra inversió directament per tal de comprovar que tan bona havia sigut la seva rendibilitat envers el risc assumit en les nostres operacions. QuantConnect automàticament fa una estimació de la volatilitat del mercat en els anys que dura la prova de Backtest, i a partir d'això i la nostra rendibilitat extreu una ràtio amb un valor de 0,304. Aquest valor ens indica que, realment, la nostra inversió no aconsegueix uns grans beneficis de cara al risc que assumeix. Aquest resultat és totalment congruent ja que ens trobem en un mercat sumament volàtil amb un risc enorme on, amb les fluctuacions de valor que ha presentat BTC en els 5 anys estudiats, el nostre 54,90005% de rendibilitat no és gran cosa si tenim en compte els possibles guanys que poden oferir aquest tipus d'actius si s'assumeixen grans riscos. També podríem associar aquest resultat al fet que, com vam poder veure en el procés de creació i programació de la IA, establim paràmetres que fan que el nostre trading bot obri o tanqui posicions de manera molt marcada en funció de les tendències del mercat de manera que no l'exposem enormement.

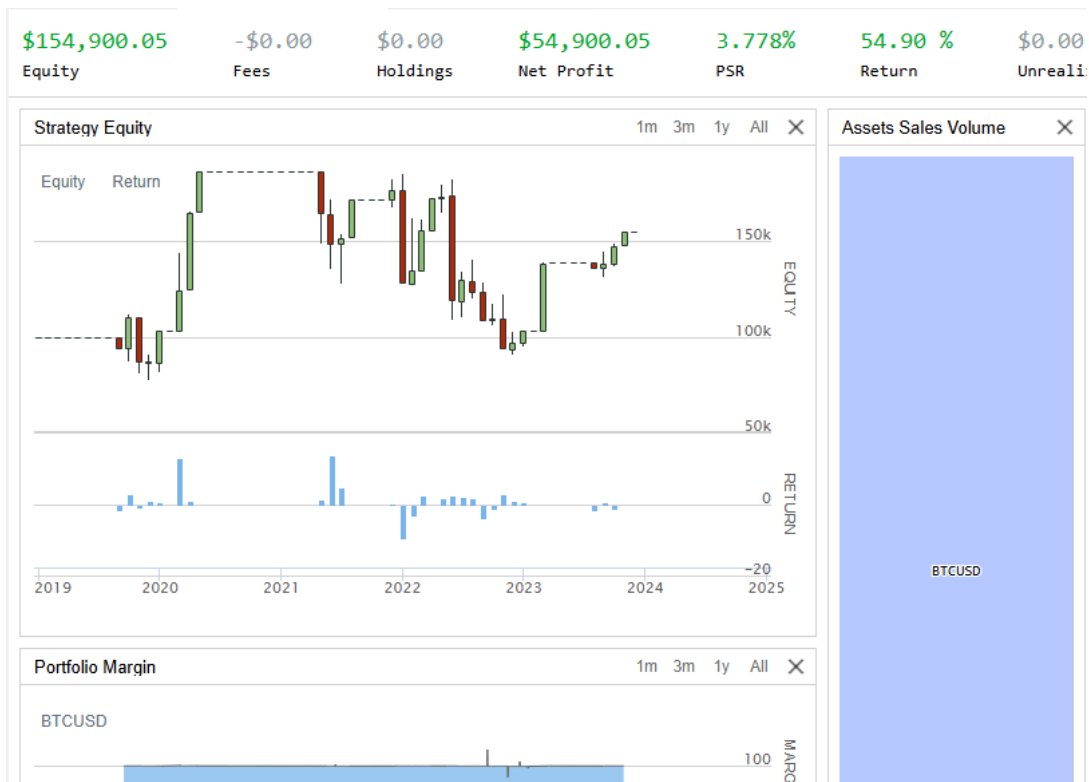
A continuació, també hem de comentar un altre indicador que va de la mà de la ràtio de Sharpe que ens va semblar molt interessant que es tingués en compte en aquest software de Backtesting i del que no havíem sentit parlar abans. Parlem del PSR (Probabilistic Sharpe Ratio). Aquest indicador es calcula fent servir una funció de distribució normal, on el que volem corroborar és si la ràtio de Sharpe que hem obtingut al nostre experiment és fruit de la sort / atzar o si té un resultat significatiu a nivell estadístic. Per calcular-ho, es fa servir tant la ràtio de Sharpe que tenim com una ràtio de referència o "benchmark" que

normalment s'estima amb un valor de 0 en la majoria dels casos. D'aquesta manera i seguint una distribució normal, podríem interpretar de la següent manera els diferents valors que pren el PSR:

- Valor de 0: ens diria que hi ha un 50% de probabilitat de que la nostra ràtio de Sharpe hagi sigut fruit de l'atzar.
- Valor de 1,65: a partir d'aquest valor estimem un 95% de probabilitat.
- Valor de 2,33: s'estimaria un 99% de probabilitat.

En el cas del nostre experiment, vam obtenir un PSR amb un valor molt alt, de 3,778. Amb un primer cop d'ull, això seria extrany si fòssim inversors convencionals ja que significaria que no hi ha pràcticament cap probabilitat de que la nostra ràtio de Sharpe obtinguda hagi sigut fruit de l'atzar. No obstant, hem de tenir en compte que aquest indicador pren valors alts habitualment en l'àmbit dels trading bots, ja que funcionen de maneres molt pautades i parametritzades que provoquen poques desviacions en les seves operacions i resultats, deixant un lloc mínim a l'atzar a l'hora de justificar els seus resultats, cosa que reforça la integritat en el treball que ha fet el nostre trader experimental.

Per últim, podríem fer una anàlisi de la volatilitat històrica del nostre trading bot. Agafant les dades que ens ofereix QuantConnect i fent una revisió del càlcul gràcies a la fórmula de la ràtio de Sharpe (ja que comptem amb els valors de la rendibilitat i la ràtio), hem pogut concloure una volatilitat del 16,669% anual aproximada per la nostra inversió. En casos normals, afirmariem que aquest valor de la volatilitat anual és més bé alt, però hem de tenir en compte que operem al mercat de les criptomonedes, on molts inversors tenen com a resultat de les seves operatives volatilitats altíssimes, cosa que ens dona certa seguretat i reafirma el fet que el nostre trading bot ha sapigut actuar sense deixar-se emportar pel sentiment de mercat i actuant només basant-se en indicadors objectius parametritzats prèviament.



Gràfic extret de la plataforma Quant Connect amb els resultats de la operativa del Trading Bot

5.3. Inversor humà

Per tal de poder comparar equitativament el nostre trading bot amb un inversor humà, hem simulat el comportament que hauria tingut un inversor actuant amb una metodologia definida mitjançant l'aplicació d'un anàlisi tècnic bàsic i amb decisions manuals de compra i venda. Aquesta simulació s'ha portat a terme amb les mateixes característiques temporals, el capital i el mateix actiu. Pot ser que en aquest període un inversor humà aconseguís un resultat totalment diferent al que farem servir, ja que cadascú es deixa influenciar d'una manera o d'una altra i això fa que no tots els traders prenguin les mateixes decisions. Per aquest motiu, hem agafat una mitjana amb les estadístiques i dades que hem trobat amb una exhaustiva cerca.

5.3.1. Dades generals prèvies a l'experiment

Hem realitzat un anàlisi amb el mateix parell que el trading bot, en aquest cas, Bitcoin (BTC)/dòlars americans (USD), juntament amb una temporalitat de 5 anys (inici de 2019 fins a inici de 2024), així simulant el mateix actiu, el mateix capital i el mateix període.

Per tant, l'inversor humà partia d'un capital inicial de 100.000 dòlars, amb la llibertat d'invertir parcialment o totalment aquest capital en funció de les condicions del mercat. Les operacions de compra i venda es realitzaven tenint en compte indicadors bàsics com el RSI (Relative Strength Index), suports i resistències, i la detecció de tendències a partir de gràfics de preu (per poder comparar-ho amb el trading bot).

Per mantenir certa objectivitat i comparabilitat amb l'estratègia del bot, es va seguir una regla bàsica: comprar quan el RSI baixava de 30 (zona de sobreventa) i vendre quan superava els 70 (zona de sobrecompra), però amb flexibilitat segons el criteri humà basat en el context del mercat i tenint en compte que, a diferència del bot, no pot estar constantment connectat observant gràfiques i dades.

5.3.2. Obtenció de dades

Per tal de poder comparar els resultats del nostre trading bot amb el d'un inversor humà hem hagut de simular el que podria obtenir una persona que operés manualment al mercat de criptomonedes. Aquesta simulació no s'ha fet de manera aleatòria, sinó que s'ha basat en fonts acadèmiques, estadístiques de mercat i perfils reals de traders per fer que els resultats siguin creïbles i coherents amb la realitat, per a establir uns paràmetres mitjans, ja que poden haver-hi casos totalment diferents on s'obté un rendiment molt elevat o inclús en el que es pot donar la situació que acabi perdent tot o gran part del capital.

-Rendibilitat acumulada i CAGR

Per estimar el rendiment total d'un inversor humà, ens hem basat en diversos estudis que analitzen el comportament típic dels inversors, com per exemple, l'estudi de Barber & Odean (2000) mostra que els inversors particulars tendeixen a obtenir un rendiment inferior al mercat per culpa de biaixos emocionals i sobreoperació, l'informe QAIB de Dalbar (2022) assenyala que els inversors individuals han obtingut una mitjana del 6,81% anual, per sota de l'S&P 500 i l'informe Morningstar (2021) parla d'una diferència mitjana de rendiment del 0,5% al 2% menys que el fons invertit, per mal "timing".

A partir d'aquests estudis, hem considerat una rendibilitat anual estimada del 6,7%, que ens dona una rendibilitat acumulada del 38,2% en 5 anys. El càlcul és:

$$\text{CAGR (taxa de creixement anual composta)} = \left(\frac{138.200}{100.000} \right)^{\frac{1}{5}} - 1 = 6,7\%$$

-Volatilitat anual

Per calcular la volatilitat anual estimada, hem consultat valors típics d'estratègies manuals en criptomonedes. Inversors que fan servir eines com el RSI o l'anàlisi tècnica bàsica tenen, segons diversos informes, una volatilitat mitjana del 12% al 16% anual. Chan (2013), en el seu llibre *Algorithmic Trading*, destaca que els traders humans tenen una volatilitat menor que els sistemes automatitzats per actuar amb més cautela. A plataformes com eToro, els inversors de perfil moderat tenen perfils de risc (volatilitat) entre el 10% i el 15% en criptodivises (dades públiques de perfils com Omar Sosa o Jaynemesis). Així doncs, hem estimat una volatilitat de 14,3% anual, que encaixa dins d'aquest rang.

-Drawdown màxim

El drawdown màxim representa la pèrdua més gran registrada durant una caiguda. En inversors humans conservadors, és habitual que aquest valor sigui menor que el d'un bot, ja que poden evitar operar en moments de molta incertesa. Segons López de Prado (2018), els humans tenen més capacitat de frenar operacions en entorns altament volàtils, tot i que això pot fer-los perdre oportunitats, per això, hem estimat un drawdown màxim de -17%, una xifra creïble per un trader actiu però prudent.

-Ràtio de Sharpe

La ràtio de Sharpe mesura la relació entre el rendiment obtingut i el risc assumit. En inversors humans, és habitual que aquest valor estigui entre 0,2 i 0,4 si no són professionals. Chan (2013) i Feng & Seasholes (2005) indiquen que una Sharpe de 0,3 és habitual en estratègies manuals senzilles. El valor 0,265 que hem assignat és coherent amb una gestió humana moderada i amb volatilitat mitjana.

-PSR – Probabilistic Sharpe Ratio

El PSR és una mètrica estadística que ens diu si la ràtio de Sharpe obtinguda pot haver estat fruit de l'atzar com hem mencionat anteriorment.

El valor assignat al nostre inversor humà ha estat de 2,890, que indica que les seves decisions probablement han estat consistents i no aleatòries.

5.3.3. Resultats obtinguts

Indicador	Inversor Humà
Capital inicial	100.000 USD
Rendiment brut final	+38.200,00 USD
Rendibilitat acumulada	+38,2%
Ràtio de Sharpe	0,265
Probabilistic Sharpe Ratio	2,890
Drawdown màxim	-17%
Volatilitat anual estimada	14,3%

Primer de tot, abans de la comparativa, procedim ara a revisar els resultats generals obtinguts per l'inversor humà, utilitzant els mateixos indicadors que hem aplicat al trading bot. Aquesta revisió es basa en una simulació manual de decisions d'inversió fetes al llarg del període comprès.

Parlem primer del rendiment brut i la rendibilitat acumulada. Durant el període analitzat, l'inversor humà va obtenir un benefici total de 38.200,00 dòlars, equivalent a una rendibilitat del 38,2%. Aquest resultat demostra una capacitat sòlida per identificar oportunitats al

mercat i mantenir una estratègia d'inversió òptima dins d'un entorn de forta volatilitat com és el de les criptodivises.

Tot i això, per valorar correctament aquesta rendibilitat, cal tenir en compte el risc assumit. La ràtio de Sharpe obtinguda ha estat de 0,265, una dada que indica que la relació entre el rendiment obtingut i la volatilitat o risc no ha estat molt significativa tenint en compte la volatilitat del mercat. Aquest valor és coherent amb una operativa humana que, tot i ser disciplinada, pot veure's afectada per la subjectivitat i per la manca de resposta immediata als canvis del mercat.

Un altre indicador rellevant que s'ha tingut en compte és el Probabilistic Sharpe Ratio (PSR), que en aquest cas ha resultat ser de 2,890. Ens indica una probabilitat estadística molt elevada que la rendibilitat obtinguda no sigui fruit de l'atzar, sinó d'una estratègia consistent i estructurada. Aquests valors superiors a 2 es consideren significatius i reforcen la solidesa dels resultats obtinguts.

Pel que fa a la màxima caiguda registrada (drawdown màxim), aquesta ha estat del -17%. Aquest indicador mostra la pèrdua màxima en què va incórrer el capital durant una caiguda temporal i reflecteix una gestió del risc raonablement conservadora, típica d'un operador que actua amb cautela davant la incertesa del mercat.

Seguint amb la volatilitat anual estimada, que ha estat del 14,3%, un valor que suggereix una operativa prudent, amb fluctuacions controlades i una exposició moderada al risc. Aquest comportament pot associar-se a una presa de decisions gradual, basada en anàlisi tècnica i sense una elevada freqüència operativa.

Els resultats observats mostren que un inversor humà disciplinat pot assolir rendiments positius i mantenir un perfil de risc controlat al llarg del temps, tot i les limitacions que implica la manca d'automatització i la influència emocional pròpia del factor humà.

5.4.Comparació de resultats

Ara que ja hem analitzat l'operativa dels nostres dos traders, és hora de comparar els seus resultats i concloure si el nostre trading bot és una bona competència pels traders humans que ens podem trobar al món dels mercats financers. La següent taula resumeix les dades més importants que hem obtingut a partir de la simulació del trading bot i la simulació

raonada d'un inversor humà, per no només comparar rendiment, sinó que altres paràmetres per a un anàlisi més exhaustiu:

Indicador	Trading bot	Inversor humà
Rendiment brut final	+54.900,05 USD	+38.200 USD
Rendiment mitjà anual	9,1%	6,7%
Ràtio de Sharpe	0,304	0,265
Probabilistic Sharpe Ratio	3,778	2,890
Volatilitat anual estimada	16,6%	14,3%

Pel que fa al rendiment mitjà anual, el trading bot ha aconseguit una mitjana del 9,1%, mentre que l'inversor humà s'ha quedat en un 6,7% anual. Aquesta diferència és significativa, ja que al llarg de 5 anys ha suposat una rendibilitat acumulada del +54,9% per al bot i del +38,2% per al trader humà, una diferència d'un 16,7%. La capacitat del bot d'actuar de forma constant i objectivament l'ha ajudat a maximitzar els guanys sense descans.

Tanmateix, si observem la volatilitat anual, podem veure que el bot també ha mostrat més variabilitat en els resultats, amb un 16,6% respecte al 14,3% del trader humà, cosa que ens indica que la persona ha actuat amb més prudència, fent menys operacions o evitant aquelles que considerava massa arriscades.

La ràtio de Sharpe, que relaciona rendiment i risc, també reflecteix aquesta realitat. El bot ha obtingut un valor lleugerament superior (0,304 envers 0,265), però cap dels dos valors es pot considerar molt alt, ambdós entren dins de l'esperat per estratègies amb volatilitat elevada com les que impliquen Bitcoin i el sector de les criptodivises.

Pel que fa al PSR (Probabilistic Sharpe Ratio), amb valors superiors a 2 en els dos casos, es pot concloure que tant el bot com l'inversor humà han aconseguit resultats estadísticament consistents. El trading bot ha obtingut un valor més alt (3,778), fet que reforça la seva fiabilitat i regularitat, mentre que el valor del trader humà (2,890) també demostra que la seva operativa ha estat sòlida i no fruit de l'atzar.

En quant al drawdown màxim, el comportament més conservador i menys volàtil del trader humà fa pensar que les seves pèrdues en moments complicats del mercat haurien estat una mica més contingudes que les del bot, per tant estimem que el bot hagués presentat un valor més elevat en aquest paràmetre.

6.Conclusions

Després d'haver treballat aquest projecte, podem dir que hem après molt tant a nivell tècnic com pràctic. Ens hem endinsat en el món del trading automatitzat i hem pogut veure, pas a pas, com es crea i s'analitza una estratègia automatitzada.

Un cop vam tenir el bot en funcionament i vam obtenir els seus resultats, vam voler comparar-los amb el que podria fer un inversor humà en les mateixes condicions: mateix capital inicial, mateix període, mateix actiu (BTC/USD) i una estratègia semblant. Com que no teníem accés a les dades d'un inversor real, vam fer una simulació a partir de fonts fiables, com estudis de Dalbar o de Barber i Odean, i perfils públics de traders. Gràcies a això, vam poder estimar una mitjana anual raonable per a l'humà (6,7%) i vam obtenir resultats coherents per fer la comparació.

Amb totes les dades sobre la taula, hem vist que el bot ha aconseguit un rendiment mitjà més alt (9,1% anual), amb una operativa constant i sense emocions. També ha obtingut una ràtio de Sharpe i un PSR superiors, fet que demostra més consistència estadística. En canvi, l'inversor humà, tot i tenir menys rendiment, ha destacat per tenir menys volatilitat i un comportament més estable. Això té sentit, perquè un inversor real pot ser més cautelós i adaptar-se millor davant situacions que un bot no pot interpretar.

Això ens mostra que no hi ha una única manera correcta d'invertir. Tant un bot com un inversor humà poden funcionar bé si es fan servir amb un criteri correcte. El trading automatitzat ens pot ajudar molt quan busquem regularitat i objectivitat sense estar pendent dels gràfics. Però el criteri humà continua sent important, sobretot en moments on cal interpretar el context o actuar amb flexibilitat.

A nivell personal, aquest projecte també ens ha servit per posar en pràctica coneixements de programació, anàlisi tècnica i gestió del risc. Hem vist com es dissenya una estratègia, com es prova i com s'avalua amb dades. A més, hem après a valorar la importància de tenir

una base estadística sòlida, d'utilitzar fonts fiables i de no quedar-nos només amb els guanys, sinó analitzar també el risc i la forma com s'han obtingut els resultats.

Podem dir que hem assolit els objectius que ens havíem proposat. El nostre trading bot, tot i ser senzill, ha demostrat que pot competir amb un inversor humà i que té potencial real per ser utilitzat. A més, ens ha fet reflexionar sobre com podem aplicar aquesta tecnologia a les nostres pròpies inversions. Automatitzar una part del procés pot ajudar-nos a ser més disciplinats, controlar millor les emocions i millorar els resultats, sobretot en mercats que són ràpids i canviants com el estudiat. Per tant, creiem que aquest tipus d'eines poden tenir un paper important en la nostra futura gestió financera personal.

En conclusió, la intel·ligència artificial és més present que mai a les nostres vides, i això no exclou el món de la inversió i els mercats financers. El nostre treball ens ha servit per trobar una resposta a la incògnita principal del nostre TFG i aquesta resposta és que, efectivament, aquesta eina ens seguirà acompanyant en aquest entorn en els pròxims anys i té el potencial per esdevindre un dels principals medis utilitzats per invertir de manera segura i rendible.

7. Bibliografia / Webgrafia

Aldridge, I. (2013). *High-frequency trading: A practical guide to algorithmic strategies and trading systems* (2nd ed.). Wiley.

- Introducció teòrica al trading algorítmic i les seves estratègies

Barber, B. M., & Odean, T. (2000). *Trading is hazardous to your wealth: The common stock investment performance of individual investors*. *The Journal of Finance*, 55(2), 773–806. <https://doi.org/10.1111/0022-1082.00226>

- Anàlisi del comportament i performativa dels inversors com a individus

Bergstra, J., Bardenet, R., Bengio, Y., & Kégl, B. (2011). *Algorithms for hyper-parameter optimization*. *Advances in Neural Information Processing Systems*, 24, 2546–2554.

- Aquest estudi dona informació sobre les tècniques d'ajustament de paràmetres en models d'IA.

Brockwell, P. J., & Davis, R. A. (2016). *Introduction to time series and forecasting* (3rd ed.). Springer. <https://doi.org/10.1007/978-3-319-52452-8>

- Ha servit per entendre els models de predicció estadística com ARIMA, aplicables al comportament temporal dels mercats.

Brownlee, J. (2017). *Deep learning for time series forecasting: Predict the future with MLPs, CNNs and LSTMs in Python*. Machine Learning Mastery.

- Explicació general i pràctica sobre com preparar, entrenar i validar models d'IA basats en aprenentatge dins del món financer.

Chan, E. P. (2013). *Algorithmic trading: Winning strategies and their rationale*. Wiley. <https://www.wiley.com/en-us/Algorithmic+Trading%3A+Winning+Strategies+and+Their+Rationale-p-9781118460146>

- Hem explorat estratègies de trading algorítmic i pràctiques de backtesting.
- Informació sobre la simulació i avaluació d'estratègies amb backtesting.

Chollet, F. (2017). *Deep learning with Python*. Manning Publications. <https://www.manning.com/books/deep-learning-with-python>

- Hem utilitzat aquest llibre per aprofundir en l'ús de xarxes neuronals i LSTM dins del trading automatitzat.

El Confidencial. (2019, 16 de setembre). *Este joven canario es uno de los inversores más copiados del mundo (y es español)*. https://www.elconfidencial.com/tecnologia/2019-09-16/inversion-etoro-inversos-espanol-mercado_2227143/

➤ Dades del trader humà com a referència

EToro. (2020). *80% technical and 20% fundamental: Meet Omar Sosa Afonso*. <https://www.etoro.com/news-and-analysis/copytrader/80-technical-and-20-fundamental-meet-omar-sosa-afonso/>

➤ Dades del trader humà com a referència

Feng, L., & Seasholes, M. S. (2005). *Do investor sophistication and trading experience eliminate behavioral biases in financial markets?* *Review of Finance*, 9(3), 305–351. <https://doi.org/10.1007/s10679-005-2262-0>

➤ Informació sobre els biaixos de mercat i el sentiment de mercat

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. <https://www.deeplearningbook.org/>

➤ Aquesta obra ens ha proporcionat les bases teòriques del deep learning, essencials per entendre com funcionen els trading bots més avançats.

➤ Estudi que menciona la importància de la qualitat de les dades en l'entrenament de IAs d'inversió.

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An introduction to statistical learning* (2nd ed.). Springer. <https://www.statlearning.com/>

➤ Hem fet ús d'aquest llibre per explicar algoritmes com la regressió lineal, logística, Random Forest i boosting.

Liu, X.-Y., Yang, H., Gao, J., & Wang, C. D. (2021). *FinRL: Deep reinforcement learning framework to automate trading in quantitative finance*. *Proceedings of the 2nd ACM International Conference on AI in Finance* (pp. 1–9). Association for Computing Machinery. <https://doi.org/10.1145/3490354.3494366>

➤ Aquesta font ens ha ajudat a conceptualitzar un marc pràctic de trading automatitzat, aplicant reinforcement learning real.

López-Lira, A., & Tang, Y. (2023). *Can ChatGPT forecast stock price movements?* University of Florida. <https://arxiv.org/pdf/2304.07619#:~:text=ChatGPT%27s%20ability%20to%20generate%20human,trained%20to%20predict%20stock%20returns.>

➤ Estudi sobre l'habilitat de la IA "ChatGPT" per predir els moviments del mercat

López de Prado, M. (2018). *Advances in financial machine learning*. Wiley. <https://www.wiley.com/en-us/Advances+in+Financial+Machine+Learning-p-9781119482086>

➤ Per tractar la validació d'estratègies algorítmiques i evitar l'overfitting.

Morningstar. (2021). *Mind the gap 2021: A report on investor returns in the United States.* <https://www.morningstar.com/lp/mind-the-gap>

Narang, R. K. (2009). *Inside the black box: A simple guide to quantitative and high frequency trading.* Wiley. <https://www.wiley.com/en-us/Inside+the+Black+Box%3A+A+Simple+Guide+to+Quantitative+and+High+Frequency+Trading-p-9780470432069>

➤ Aquest llibre ens ha ajudat a descriure el funcionament intern dels HFT bots, que operen a mil·lisegons.

Reglamento (UE) 2023/1114 del Parlamento Europeo y del Consejo, de 31 de mayo de 2023, sobre los mercados de criptoactivos, por el que se modifica el Reglamento (UE) nº 1093/2010, el Reglamento (UE) nº 1095/2010 y las Directivas 2013/36/UE y (UE) 2019/1937. Diario Oficial de la Unión Europea, L 150, 9 de junio de 2023, pp. 40–205. [Wikipedia+1Wikipedia+1](#)

Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction (2nd ed.).* MIT Press. <http://incompleteideas.net/book/the-book-2nd.html>

➤ Hem comprès l'aprenentatge per reforç, que hem aplicat a la descripció de com els bots aprenen per recompenses o penalitzacions.

Zhang, Y., & Zohren, S. (2020). *Machine learning for trading.* Oxford-Man Institute of Quantitative Finance. <https://arxiv.org/abs/2006.14548>

➤ Ens ha proporcionat suport per justificar que el ML pot predir tendències de mercat millor que mètodes tradicionals.