




ROADMAP QUANT



Conceitos e referências

 Trading com Dados

apresenta

ROADMAP QUANT



1a edição, setembro/22

Este e-book faz
parte do evento

Jornada Quant

Este e-book conta com o apoio da



Disclaimer

Jornada Quant

27 a 30 de setembro

Este e-book foi desenvolvido como material de apoio para a Jornada Quant, que acontecerá entre os dias 27 e 30 de setembro. Não é permitido sua transferência ou venda.

® Trading com Dados e suas marcas são propriedade registrada da Trading Tratamento de Dados, Ltda. Todos os direitos reservados.

Índice

Apresentação	6
A origem do termo “quant”	9
A análise quantitativa	9
Introdução ao mundo das finanças quantitativas	11
Um breve histórico	14
Pilares fundamentais	17
Habilidades necessárias	22
Carreiras em finanças quantitativas	29
Data Science dentro das finanças quantitativas	33
Como entrar no mercado financeiro?	38
O cenário atual das finanças quantitativas	41
Livros	42
Para continuar aprendendo	48
Referências	49

Apresentação

Fala pessoal, tudo bem?

Se você chegou até aqui, provavelmente deve ter interesse em algum destes temas: mercado financeiro, programação, estatística, matemática, ciência de dados, seja eles separadamente ou mesmo todos ao mesmo tempo.

Além disso, muito provavelmente tem interesse também no crescimento da área **quant** dentro do mercado financeiro e as oportunidades que ela traz consigo, inclusive oportunidades para sua própria carreira.

Cada vez mais o mercado financeiro tem procurado por profissionais com habilidades analíticas e quantitativas e isso se traduz numa enorme oportunidade como vamos ver aqui.

Este e-book foi desenvolvido com o intuito de orientar profissionais na área de finanças quantitativas, mas não impede que investidores buscando melhorar sua tomada de decisão se beneficiem com os conhecimentos e as referências aqui colocadas. Acreditamos que usar as habilidades em ferramentas quantitativas só traz benefícios, seja para sua carreira ou para a sua carteira, como gostamos de falar por aqui.

Ao longo dessa nossa jornada de alguns anos no mundo da ciência de dados e das finanças quantitativas, pudemos entender um pouco mais sobre como funciona esse setor praticamente ainda inexplorado no Brasil, e o que pode gerar uma vantagem competitiva para quem busca um lugar ao sol.

Assim, este e-book servirá como um primeiro guia, um manual de referências que você poderá consultar para dar os seus primeiros passos e retornar sempre que necessário, além de te indicar onde buscar informações e conhecimentos relevantes para se desenvolver na área.

Vale ressaltar que esta é a primeira versão deste e-book, que será continuamente atualizada e desenvolvida com o tempo, e portanto, trará cada vez mais informações e detalhes valiosos para te ajudar nesta jornada rumo à carreira como um **quant**.

Vamos lá?

Esperamos que seja o início de uma jornada de sucesso para você.

Grande abraço,

Equipe Trading com Dados

“Eu acredito firmemente que, para todos os bebês e um número significativo de adultos, a curiosidade é uma motivação maior do que dinheiro”

Elwyn Berlekamp (1940-2019)

Matemático e empresário americano

Citação extraída do livro “The man who solved the market” - Gregory Zuckerman

A origem do termo “quant”

O termo **quant** é uma forma curta de descrever a área da análise quantitativa, que por sua vez no mercado financeiro acaba sendo um sinônimo de finanças quantitativas, que vamos detalhar daqui a pouco.

A palavra **quant** também é utilizada comumente para designar os profissionais que trabalham nesta área, os **analistas quantitativos**.

A análise quantitativa

Se você conhece ou atua no mercado financeiro há algum tempo, provavelmente já se deparou com as escolas clássicas: a análise técnica e a análise fundamentalista.

Cada uma delas tem os seus pontos fortes e fracos, e cada uma delas também possui ramificações com as suas particularidades. Dentro da análise fundamentalista, por exemplo, encontramos os adeptos do *buy-and-hold* e do *value investing*.

A análise técnica procura por padrões nos gráficos, tendências nas informações de preço, volume, etc. A análise fundamentalista se concentra nos indicadores financeiros da empresa e como eles variam com o tempo.

Há ainda uma outra escola, que não é tão conhecida dos investidores, que utiliza matemática, estatística, dados e programação para a tomada de decisões. Estamos falando da **análise quantitativa**.

Desta forma, ela se diferencia da forma como a análise técnica e fundamentalista atuam, por basear suas decisões não em padrões


gráficos ou resultados trimestrais das empresas, e sim no resultado de modelos matemáticos, estatísticos ou ainda com base na análise e ciência de dados, modelos de machine learning e *alternative data* (dados alternativos), como tem sido feito nos últimos anos.

Estamos falando de um novo paradigma na tomada de decisão do mercado financeiro, paradigma este que pode inclusive abarcar indicadores e ferramentas da análise técnica e fundamentalista.

Já imaginou utilizar aspectos da análise técnica e da análise fundamentalista simultaneamente em uma estratégia? Utilizando dados e programação, isso se torna possível.

Utilizando ainda os conhecimentos em estatística e matemática, podemos ter uma tomada de decisão *data-driven* (orientada a dados), pragmática e sem os vieses humanos que poderiam afetar nosso julgamento como em outras escolas do mercado financeiro.

Muito embora o uso de matemática e estatística para tomar decisões no mercado financeiro vem desde o início do século XX, foi mais recentemente graças ao trabalho desenvolvido no hedge fund americano Renaissance Technologies pelo seu fundador, James (Jim) Simons, que a análise quantitativa ganhou destaque.



Jim Simons, matemático fundador da Renaissance Technologies

Introdução ao mundo das finanças quantitativas

Agora que já entendemos que existe uma outra escola de mercado financeiro, vamos adentrar na área técnica que dá vida a análise quantitativa, que são as finanças quantitativas.

De forma geral, o termo “finanças quantitativas” do inglês “*quantitative finance*” designa o uso de conhecimentos em estatística, dados e tecnologia para a análise e tomada de decisões no mercado financeiro.

Aqui, podemos fazer uma distinção entre a visão clássica das finanças quantitativas e a visão mais recente.

Até meados dos anos 90, a visão clássica era de que as finanças quantitativas eram somente o uso de modelos matemáticos e estatísticos para a criação de equações e regras que descreviam o mercado financeiro. Alguns exemplos da visão clássica desta área incluem:

1. Precificação de derivativos como opções
2. Gestão de risco, especialmente ligada aplicações de gestão de portfólios

Com o avanço da computação, da tecnologia de hardware e software, especialmente ao fim dos anos 90 e início dos anos 2000, um volume gigantesco de dados passou a ser obtido de diferentes fontes. Isso abriu uma nova perspectiva na área das finanças quantitativas. Isso porque essa infinidade de dados e de ferramentas de *data science* possibilitou o uso desses dados também no mercado financeiro.


Existe um poder computacional cada vez maior, o que faz com que mesmo um cidadão comum consiga obter, processar e analisar um grande volume de dados. Dessa forma, mesmo sem ter um background desenvolvido em matemática ou estatística, pode-se utilizar os dados para auxiliar na tomada de decisões, ou seja, usar as finanças quantitativas mesmo sem ter o domínio de modelagem matemática.

Um exemplo recente é o uso de dados alternativos para a detecção de padrões e de relações entre variáveis que não são tão óbvias no mercado financeiro. Por exemplo: hedge funds que utilizam dados de navios para fazer projeções nos preços das commodities, ou ainda outros que monitoram dados de tráfego aéreo para tentar se antecipar a alguma operação de fusão ou aquisição (M&A) entre grandes empresas.



Dados alternativos têm sido utilizados com o objetivo de gerar 'alfa', isto é, retorno em excesso acima do benchmark de mercado. Fonte: Integrity Research Associates.

A ideia aqui é que qualquer dado, de qualquer origem, pode ser testado, avaliado e comparado ao desempenho de algum ativo para a detecção de padrões. Sejam dados de negociação (*trading*), dados do comportamento dos investidores (análise de sentimento do Twitter, por exemplo), dados meteorológicos, movimentações de navios, aviões, carros, etc. Aqui a criatividade é o limite, e os *players* que conseguem obter e testar o maior volume e variedade de dados acabam saindo na frente.



A determinação da superfície de volatilidade implícita de opções é uma aplicação da área das finanças quantitativas.

Fonte: Stony Brook University

Um breve histórico

Mas será que sempre foi assim? Como as finanças quantitativas se desenvolveram e se tornaram o que são hoje? Vamos fazer uma breve retrospectiva.

Não há um consenso na definição do surgimento das finanças quantitativas, mas se concorda que o primeiro trabalho desenvolvido utilizando matemática avançada para modelar um problema do mercado financeiro foi a tese de doutorado do matemático francês Louis Bachelier (1870 - 1946), intitulada "*A teoria da especulação*", que propunha um modelo para precificar opções de acordo com uma distribuição normal.

Anos mais tarde, em 1952 o economista americano Harry Markowitz traz em sua tese de doutorado "*Portfolio Selection*" noções matemáticas e estatísticas ao processo de criação de uma carteira de investimentos que não eram comuns até então. Ele deu origem a Teoria Moderna de Portfólios, e este trabalho lhe rendeu o Prêmio Nobel de Economia em 1990.

Markowitz utilizou noções como média dos retornos e covariâncias para determinar como diversificar portfólios de forma apropriada, evitando ativos altamente correlacionados entre si. Apesar de ter sido uma das primeiras contribuições no campo da otimização de portfólios e já haver ferramentas mais avançadas, sua contribuição representou um marco na área das finanças.

Na década de 60, matemáticos e estatísticos iniciaram o uso de computadores e volumes massivos de dados para analisar padrões no mercado financeiro. Neste cenário, o trabalho de Edward Thorp se

destacou por ter sido o primeiro matemático moderno a usar estratégias quantitativas para investir um volume considerável de dinheiro. Por causa disso, ele é muitas vezes considerado o “pai do investimento quantitativo”. Thorp era professor na New Mexico State University e na University of California em Irvine, e trabalhou com Claude Shannon, considerado o pai da teoria da informação. Depois de ler livros sobre análise técnica e também o “Security Analysis”, de Benjamin Graham e David Dodd, Thorp disse em sua autobiografia que ficou surpreso mas também motivado ao ver o pouco conhecimento que se tinha do mercado financeiro pelo público em geral.

Em 1965, Paul Samuelson introduziu o cálculo estocástico dentro do mundo das finanças, tema que foi desenvolvido e aperfeiçoado por Robert Merton, que buscou entender como os preços se comportam nos mercados financeiros. Nesta mesma época, os economistas Fischer Black e Myron Scholes, com a ajuda de Merton, desenvolveram o modelo de Black-Scholes, que tem como objetivo encontrar o preço justo para opções européias.

Em 1972, Eugene Fama e Merton Miller publicaram a obra “Theory of Finance”, onde Fama explora a hipótese do mercado eficiente. Em 1976, o economista americano Stephen A. Ross publica um artigo sobre teoria de arbitragem de preços, demonstrando que os retornos dos ativos podem ser explicados por múltiplos fatores, dando origem à área conhecida como *Factor Investing*. O próprio Fama traria sua contribuição em 1993 junto com Kenneth B. French, quando publicaram um artigo que demonstrava que os retornos esperados de ações de valor (value stocks) eram maiores que os de ações de crescimento (growth stocks). Isso deu origem ao modelo de fatores conhecido como “três fatores de Fama French”.

Mais recentemente, uma série de pesquisadores tem avançado em pesquisas principalmente em áreas como: otimização de portfólio, gestão de risco, utilização de aprendizado de máquina (machine learning) na otimização do trading, dentre outros temas. Ao fim deste livro, traremos uma série de referências de profissionais, livros e artigos para te ajudar nesta caminhada.




Eugene Fama, um dos criadores dos “três fatores de Fama French”

Pilares fundamentais

Ao adentrar no mundo das finanças quantitativas, é fundamental estudar os pilares que compõem esta área. Existem algumas definições diferentes sobre os tópicos que compõem esta área, principalmente se variarmos entre a definição clássica e a versão mais recente.

De toda forma, para começarmos com uma definição mais abrangente, podemos entender a área de finanças quantitativas como sendo composta dos pilares de tecnologia, finanças, e estatística/matemática. Observe na imagem abaixo que as finanças quantitativas estão localizadas na interseção entre essas três áreas.



Ao longo dos próximos parágrafos vamos detalhar cada um destes pilares e os subtópicos que estão contidos neles.

Finanças

Dentro do pilar de finanças, temos todo o conhecimento do funcionamento do mercado financeiro que é indispensável para qualquer analista quantitativo. Seja na renda fixa, ou renda variável, é necessário ter uma boa noção das características de cada produto. É comum ver quants especializados na modelagem de alguma classe de ativo específico e portanto com domínio das suas particularidades. Como exemplos de subgrupos dentro de finanças, podemos mencionar:

- **Trading:** o termo "*trading*" em inglês quer dizer "negociação", ou seja, representa o ato de comprar e vender ativos com o objetivo de conseguir algum lucro. É importante que o quant conheça as diferentes modalidades de negociação, trabalhar com timeframes diferentes, como desenvolver e testar estratégias lucrativas, etc.
- **Mercado financeiro:** conhecer as diferentes modalidades de produtos financeiros, como commodities, câmbio, juros, *equities*, títulos de renda fixa, derivativos, etc. É importante destacar que não existe uma graduação específica para mercado financeiro (ou finanças) no Brasil, sendo portanto um conhecimento adquirido por conta própria, seja no estudo individual ou trabalhando no mercado financeiro.
- **Economia:** é importante entender como a economia influencia o desempenho dos ativos que são negociados, e criar projeções para auxiliar nas estratégias. O conhecimento em macroeconomia vai trazer noções importantes da dinâmica de indicadores como inflação e juros, por exemplo, com a direção do mercado.

- **Microestrutura de mercado:** o entendimento sobre como os ativos são negociados, precificados e se movem de acordo com diferentes condições. Aqui, estudamos métricas como volume de ordens ao longo do tempo, como ordens de compra estão posicionadas vs. ordens de venda, o spread entre ordens de compra e venda, etc. Um dos conceitos estudados aqui é o da profundidade de mercado (*Depth of Market, MOD*), que pode ser definida como a capacidade do mercado (ou de um ativo específico) de absorver ordens relativamente grandes sem impactar de forma significativa o seu preço. Utilizar o conhecimento em microestrutura de mercado pode ser útil para encontrar disparidades na configuração de ordens de um ativo e vai trazer oportunidades para lucrar em cima dessas distorções.



Exemplo de estudo de microestrutura para o mercado canadense. Observe as variáveis estudadas dentro da profundidade de mercado (book depth): distribuição do tamanho, das horas das ordens, e das faixas de preço. Fonte: OneMarketData, OneTick. <https://www.onetick.com/use-cases/canadian-equity-market-microstructure>

Estatística & Matemática

O arcabouço de estatística e matemática de um analista quantitativo precisa ser robusto. Conhecimentos de estatística são usados praticamente o tempo todo, e muitas das noções de criação e avaliação de estratégias de negociação são mensuradas em termos estatísticos. Um dos exemplos mais clássicos, por exemplo, são os testes de hipótese, que são bastante utilizados no desenvolvimento de novas estratégias.

- **Álgebra linear:** com frequência, você precisará trabalhar com elementos como vetores (ou arrays) e matrizes, e realizar operações como transposição de matrizes, produto interno entre vetores, multiplicação de matrizes, dentre outras aplicações. Na análise de média-variância, utilizamos esse conhecimento para calcular os retornos esperados e volatilidade de portfólios contendo quaisquer combinações de ativos. Para você ter uma ideia, o retorno esperado de uma carteira na Teoria Moderna do Portfólio é dado pelo produto interno entre o vetor transposto do peso de cada ativo na carteira e o vetor dos retornos de cada um desses ativos. Este é um exemplo clássico de um uso de álgebra linear no mercado financeiro.
- **Modelagem:** campo da matemática e estatística utilizado para encontrar equações que representam determinados fenômenos. Ou seja, literalmente “modelar” estes fenômenos em termos matemáticos. Aqui, utiliza-se de diversas técnicas matemáticas para se atingir este objetivo, desde equações mais simples como regressões lineares, até equações diferenciais ou cálculo estocástico. Outro exemplo de aplicação são as leis de potência obtidas através das variações de preços, pois são importantes na análise do comportamento do mercado financeiro (Melgaço, 2021).

- **Estatística:** é importantíssimo ter uma base sólida em estatística para se trabalhar com análise quantitativa. Isso porque frequentemente estamos lidando com conceitos como média, mediana, variância, desvio-padrão, histograma, curtose, dentre outros termos importantes. Subáreas da estatística como séries temporais representam um conhecimento imprescindível para determinar as características de observações de dados ao longo do tempo, o que é o caso do preço de ações, por exemplo.
- **Otimização:** ramo da matemática aplicada que adquiriu importância por causa da ampla variedade de aplicações e da disponibilidade de algoritmos eficientes. Em termos matemáticos, se refere à minimização (ou maximização) de uma dada função objetivo com várias variáveis de decisão que devem satisfazer restrições funcionais. Um modelo típico de otimização tem como objetivo alocar recursos escassos entre alternativas possíveis de forma a maximizar uma função objetivo, como por exemplo o lucro total (Cornuejols, Tütüncü, 2006).
- **Probabilidade:** é o estudo dos eventos e resultados que envolvem incerteza. Investimentos no mercado financeiro, como você deve imaginar, envolvem um elevado nível de incerteza. Nada mais natural, portanto, que a probabilidade seja uma das áreas analíticas mais importantes e utilizadas no mercado financeiro. A probabilidade permite calcular métricas como valor esperado e precificar derivativos. Ela é utilizada em uma ampla gama de aplicações, desde o cálculo do valor de um simples investimento em ações até a precificação de derivativos exóticos.
- **Ciência de dados:** embora não seja exatamente uma subárea dentro da estatística ou matemática, incluímos a ciência de dados aqui por ter nascido da junção da estatística com as ciências da computação, ou falando de maneira mais ampla, com as tecnologias de dados. Vamos dar um enfoque especial à esta área numa seção posterior.

Habilidades necessárias

A seção anterior trouxe os pilares que formam as finanças quantitativas. Você pode utilizar esse framework para te auxiliar na hora de desenvolver seu arcabouço de conhecimento para entrar na área. Nessa seção, vamos trazer uma perspectiva mais prática, e detalhar em termos de carreira como esses pilares podem ser desenvolvidos e implementados. Vamos trazer em termos mais técnicos o ferramental utilizado no dia a dia de quants.

Tecnologia

Os quants, assim como cientistas de dados no mercado financeiro, precisam criar uma “caixa de ferramentas” contendo habilidades de obtenção, processamento e análise de dados.

Com o crescimento da área de dados nos últimos anos, novas ferramentas e funcionalidades surgem praticamente a cada dia. De forma geral, é importante dominar uma linguagem flexível para realização das tarefas analíticas, onde as mais utilizadas são o Python e o R, sendo que a influência do Python tem aumentado consideravelmente com este se tornando recentemente a linguagem de programação mais popular do mundo (pode oscilar, mas permanece no top 3).

Dentro das habilidades de dados, é importante que o quant (e também o cientista de dados) tenha familiaridade com o processo de ETL. Ou seja, precisa ser capaz de obter e processar dados de diferentes fontes e formatos, sejam estruturados ou desestruturados. Uma habilidade fundamental neste ponto é dominar a linguagem SQL e ter

familiaridade com SQL Server. Ferramentas de big data como Hadoop e mais recentemente o Spark tem se consolidado.

Com o crescimento da utilização de tecnologias de nuvem para armazenamento e processamento, é interessante também desenvolver o conhecimento em ferramentas como Azure ou AWS.

Mesmo que o cientista de dados ou quant tenha de fato um escopo mais analítico e não trabalhe com atividades de engenharia de dados, é importante ter familiaridade com noções de pipeline de dados. Ferramentas como o Apache Airflow ajudam muito neste sentido.

Observe que trouxemos aqui a programação do ponto de vista analítico, mas é importante também desenvolver a noção da programação orientada a objeto, e a programação para desenvolvimento de aplicações. Muito do trabalho do quant vai ser no sentido de criar pipelines de dados que serão processados para a geração de trading signals, ou seja, sinais de trading para orientar a tomada de decisão de quando entrar e sair de um trade.

Neste sentido, você vai utilizar o Python (por exemplo) para automatizar rotinas e processos, extrair dados da web (*web scraping*) e estruturar programas para avaliar o desempenho teórico de alguma estratégia que você criou utilizando dados do passado (backtesting). Tudo isso está dentro do possível escopo de atuação de um analista quantitativo.

Há ainda a figura do *quant dev*, um profissional de viés quantitativo mas que fica mais responsável pela implementação das estratégias em si, e que por causa disso precisa dominar linguagens que garantam uma latência mais baixa na execução. Chamamos essas linguagens de “baixo nível”, pois elas estão “mais próximas” do processador, ou seja, precisam de menos interpretação e abstração por parte do computador

para serem executadas, e por isso garantem que as rotinas sejam mais eficientes. Como exemplos dessas linguagens temos o C, C++ e o Java. Neste sentido, o Python não é uma linguagem de baixo nível, por ter sido implementado em linguagem C. Normalmente, assets e traders institucionais que operam em alta frequência (High Frequency Trading - HFT) optam por realizar a implementação das suas estratégias em linguagens de baixo nível, justamente para ter a vantagem de uma baixa latência, algo que não seria atingido com o Python.

Quanto maior o número de ferramentas que você conhecer e dominar nesta área, maiores as chances de sucesso na sua carreira. Um quant que domina Python pode ir bem longe, e se você adicionar linguagens como C, C++ ou Java certamente terá um leque muito maior de possibilidades.

Além disso, a união do poder computacional dos últimos 30 anos junto a técnicas estatísticas deu origem à área que chamamos de *data mining*, e mais recentemente *data science*. Modelos como *árvores de decisão*, *regressão linear* ou *regressão logística* possuem algumas décadas (ou mesmo séculos) de existência, mas foi graças ao grande volume de dados e às tecnologias capazes de processá-los e analisá-los que conseguimos chegar ao patamar atual da ciência de dados.

Finanças

De forma geral, o termo “mercado financeiro” inclui qualquer lugar ou sistema que provê a compradores e vendedores os meios para negociar (*trade*) instrumentos financeiros, como renda fixa (*bonds*), ações (*equities*), câmbio (*foreign exchange, forex*), derivativos, dentre outros.

Como afirmamos anteriormente, não há uma graduação formal em finanças e mercado financeiro no Brasil. Por isso, adquirir experiência e conhecimento sobre como funciona o mercado financeiro será um caminho árduo e neste ponto precisamos ser transparentes sobre a existência dessas dificuldades.

Uma das melhores formas de entender como o mercado financeiro funciona é trabalhando nele. Seja entrando pela porta do “backoffice”, ou como analista, seja de buy-side ou sell-side, a convivência diária com os problemas e a realidade do mercado vai te dar o embasamento que você precisa para tomar decisões que fazem sentido. Em uma das seções posteriores deste e-book, vamos detalhar algumas portas por onde você pode entrar no mundo do mercado financeiro.

Outra opção são os estudos por conta própria. Com o crescimento do mercado financeiro no Brasil, várias opções de cursos e treinamentos têm surgido nas mais diversas áreas, e acreditamos que você deve tirar vantagem desse processo, seja através de certificações, ou mesmo do estudo por conta própria.

Trazemos a seguir uma lista de algumas subáreas do mercado financeiro que são importantes conhecer. Note que esta não é uma lista exaustiva, mas que busca dar uma ideia dos temas que são estudados e utilizados no dia a dia do mercado financeiro.

- Renda Fixa
 - Títulos públicos
 - Títulos privados: CDB, CRI, CRA, LCI, LCA, etc.
 - Curva de juros
- Renda variável
 - Produtos e suas dinâmicas
 - Análise técnica
 - Análise fundamentalista
- Macroeconomia
- Derivativos
- Finanças corporativas
- Gestão de portfólio
- Asset allocation

Uma dica interessante é utilizar como referência a tabela do conteúdo programático do CFA:

Session	Functional Area	Topic	Exam Weight
1	Ethical and Professional Standards	Ethical and Professional Standards	15-20%
		Tools	8-12%
	Financial Statement Analysis	Economics	8-12%
		Financial Statement Analysis	13-17%
		Portfolio Management and Analysis	8-12%
2	Portfolio Management and Analysis	Corporate Issuers	8-12%
		Portfolio Management	5-8%
	Assets	Equity Investments	10-12%
		Fixed Income	10-12%
		Derivatives	5-8%
		Alternative Investments	5-8%

Fonte: <https://www.cfainstitute.org/en/programs/cfa/exam/level-i>

Estatística & Matemática

De forma geral, apresentamos na seção anterior as principais subáreas que os quants devem se aprofundar. Para quem tem formação em exatas, este pilar de conhecimento acaba sendo desenvolvido naturalmente graças a disciplinas como Cálculo, Álgebra Linear, Estatística, Métodos Numéricos, dentre outras. Para quem não tem formação em exatas, recomenda-se desenvolver essas habilidades através de uma pós-graduação, mestrado, ou mesmo por conta própria. Bons exemplos neste sentido são o mestrado do IMPA (Instituto de Matemática Pura e Aplicada) ou da certificação CQF (Certificate of Quantitative Finance).


Hoje, graças à adesão cada vez maior à programação, com destaque para a linguagem Python, várias ferramentas estatísticas agora podem ser utilizadas com a execução de uma simples linha de código. Com o crescimento da comunidade de Python e um número cada vez maior de bibliotecas, é possível fazer uma análise exploratória de dados ou testes de hipótese, por exemplo, sem a necessidade de ter um conhecimento profundo de programação.

É importante perceber que à medida que a tecnologia de hardware e software avançou no fim dos anos 90 e início dos anos 2000, a área da análise quantitativa ganhou uma roupagem muito mais tecnológica e orientada a dados do que era praticado antes.

O mundo quantitativo 'clássico', por assim dizer, antes do advento da era do 'big data', era focado inicialmente na precificação de derivativos, e usava principalmente o arcabouço matemático, como equações diferenciais parciais e cálculo estocástico para resolver problemas de precificação, volatilidade, etc.

Com o ganho de poder computacional, não só gestores como também mais recentemente investidores individuais, passaram a tirar proveito de ferramentas de *data science* para auxiliar na sua tomada de decisão. Assim, temos o poder da programação, análise exploratória de dados, ferramentas de bancos de dados e cloud, aliada à modelagem matemática e ao arcabouço estatístico que foi desenvolvido décadas antes.

Nesse cenário, modelos de machine learning, seja de classificação, regressão ou clusterização, vem ganhando força. Muitos destes modelos foram criados há décadas, mas hoje, graças à disponibilidade de um grande volume de dados e ferramentas e softwares, ficou muito mais palpável a implementação destes modelos no dia a dia.



Um exemplo recente de uma utilização de machine learning no mercado financeiro é o algoritmo de otimização de portfólios “Hierarchical Risk Parity”, desenvolvido pelo quant e professor espanhol Marcos Lopez de Prado, em 2016. Este algoritmo utiliza, dentre outras coisas, um modelo de clusterização chamado Hierarchical Clustering. Fonte: Hudson and Thames.

Carreiras em finanças quantitativas

Agora que já sabemos o que são os analistas quantitativos e os conhecimentos que eles precisam ter, vamos entender melhor como eles trabalham. Os quants são comumente empregados em gestoras de recursos (assets), mas também trabalham em corretoras, casas de research, bancos de investimento, dentre outros.

Numa asset quantitativa, você verá normalmente uma divisão de atividades. Há a possibilidade, por exemplo, de ter um perfil mais forte nos pilares de **Estatística** e **Finanças**, e dessa forma ajudar na modelagem macroeconômica (econometria). Ou um perfil com os pilares de **Tecnologia** e **Finanças** mais desenvolvidos tenderá a trabalhar na parte de desenvolvimento, na implementação (deploy) de estratégias, mais conhecido como *quantitative developer*, ou “**quant dev**”. Existem alguns tipos de operações onde os quant dev podem se destacar e não exigem tanto conhecimento em estatística/matemática, como é o caso das operações de arbitragem.

De forma geral, é importante fazer o diagnóstico do próprio perfil profissional para entender onde estão seus pontos fortes e fracos. Se você programa em Python há bastante tempo, é formado em exatas mas não conhece muito sobre o conhecimento do mercado financeiro, dedique-se num primeiro momento no estudo de finanças. Ao longo do tempo, utilize o conhecimento adquirido em finanças junto com as suas habilidades em programação para desenvolver projetos de finanças quantitativas para o seu portfólio.

Já se você tem um background de economia e entende também de estatística, dedique-se à programação. Para quem nunca programou, um primeiro contato com alguma linguagem de programação pode ser algo desafiador, por conta da necessidade de desenvolver o raciocínio lógico para transmitir suas idéias para o código. Isso é um processo completamente natural. Após alguns meses de prática constante,

resolução de exercícios e criação de projetos por conta própria, você terá autonomia para desenvolver suas próprias análises.

Como já vimos aqui ao longo deste e-book, o pilar de tecnologia vem ganhando cada vez mais espaço dentro do mundo das finanças quantitativas, e isso será cada vez mais intenso. Portanto, é imprescindível que você conheça alguma linguagem de programação. Por conta da versatilidade, facilidade de aprender, disponibilidade de material e por contar com uma comunidade gigantesca mundo afora, recomendamos que você comece pelo Python. De todas as áreas e subáreas que compõem as finanças quantitativas, a programação vai ser na maior parte das vezes a mais desafiadora. Assim, se você conseguir adquirir familiaridade e gosto pela programação, certamente vai sair em vantagem.

Outro aspecto importante: não é necessário se tornar um analista quantitativo para se trabalhar com finanças quantitativas. Há uma série de outros cargos onde você pode aplicar os conhecimentos em quant e extrair vantagens deles. Por exemplo, há uma tendência recente de **assessores de investimentos** que buscam aprender os conhecimentos de finanças quantitativas para embasar melhor suas decisões e recomendações.

Há também os **traders** que desenvolvem habilidades em programação para ajudar na tomada de decisões e para se tornarem menos suscetíveis às emoções e vieses humanos. Um outro exemplo são os analistas de research que utilizam a programação para ampliar o leque de dados que eles podem obter e analisar, e ainda as técnicas de análise exploratória que garantem recomendações mais embasadas. A moral da história que nós enxergamos aqui é que virtualmente qualquer área do mercado financeiro que precisa tomar alguma decisão com relação a investimentos pode e **deve** utilizar as finanças quantitativas.

Vamos trazer aqui algumas profissões que podem utilizar as finanças quantitativas. Tradicionalmente, os profissionais que trabalham de forma intensiva com a bagagem de finanças quantitativas são:

- Analista quantitativo
- Analista de risco
- Analista de pricing
- Quant Portfolio Manager
- Quantitative Developer (Quant Dev)
- Quantitative Strategist (Strats)
- Quantitative Trader
- Quantitative Researcher

Há também os profissionais que não utilizam obrigatoriamente o conhecimento em finanças quantitativas no seu dia a dia, mas pontualmente podem aplicar conceitos, ferramentas e técnicas da área. Acreditamos que esses profissionais podem se beneficiar (e muito) por adquirirem expertise nas finanças quantitativas:

- Analista de dados
- Cientista de dados
- Engenheiro de dados
- Desenvolvedor/engenheiro de software
- Analista de research
- Analista de investimentos (buy-side ou sell-side)
- Assessor de investimentos
- Analista de backoffice

É comum ainda hoje que muitas tarefas operacionais e analíticas do mercado financeiro sejam feitas com o Excel. Isso é verdadeiro não só no Brasil, e esse é um cenário que dificilmente vai mudar. Isso porque o Excel é relativamente fácil de utilizar e permite o gerenciamento e análise dos dados em alguns simples passos, não exigindo para isso conhecimentos em programação. Apesar de o Excel ser muito utilizado inclusive na análise quantitativa, acreditamos que quem quiser trabalhar com **quant** de fato **precisa aprender alguma linguagem de programação**.

Muito do que se faz como analista quantitativo tem uma interseção considerável com o cargo de cientista de dados e envolve poder computacional. Seja na obtenção, processamento ou análise dos dados, seja na modelagem matemática de algum ativo, ou mesmo na criação, backtesting e implementação de alguma estratégia.

Não é possível explorar todo o poder que o mundo **quant** tem a oferecer se ficarmos restritos ao Excel. Perceba que aqui não estamos diminuindo a importância do Excel ou dizendo que você precisa “esquecer” esta ferramenta. Ele é sim muito versátil, prático e em várias situações é o que precisamos para resolver alguns problemas. Mas para o mundo da análise quantitativa saber Excel não é suficiente. Além disso, dominar uma linguagem de programação vai garantir a escalabilidade que você precisa para implementar estratégias quantitativas.

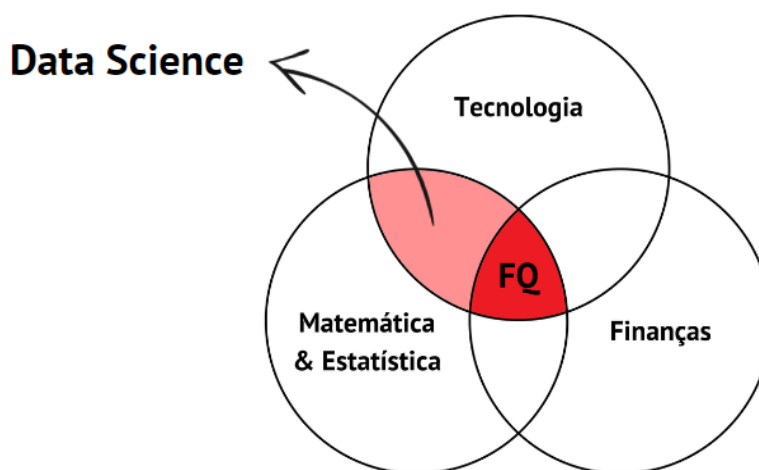
Isso é ainda mais verdadeiro quando a velocidade de execução é levada em consideração na estratégia. No caso do High Frequency Trading (HFT), a latência é tão importante que normalmente se opta por uma linguagem que consiga enviar ordens mais rapidamente (C e Java, por exemplo).

Data Science dentro das finanças quantitativas

Até agora, focamos nos 3 pilares principais que formam as finanças quantitativas: Tecnologia, Finanças e Matemática/Estatística. No entanto, há uma subárea que foi mencionada aqui várias vezes e que merece um destaque especial. Estamos falando da ciência de dados (*data science*), um campo que vem revolucionando o mercado financeiro nos últimos anos.

Para entender melhor como a ciência de dados surgiu no meio de tudo isso, é importante ressaltar que esta área cresceu graças aos avanços computacionais das últimas décadas. Muito do arcabouço teórico utilizado em *data science* já estava presente na estatística décadas antes, mas foi a tecnologia de armazenamento e processamento de dados que possibilitou a análise de um grande volume de informações.

Em termos gerais, podemos enxergar então a ciência de dados como a união da estatística com a tecnologia, especialmente ciências da computação e tecnologia da informação. Se tivéssemos que localizar *data science* no nosso diagrama dos pilares das finanças quantitativas, ela estaria localizada na junção da Estatística/Matemática com a Tecnologia:



Data science como área é extremamente recente, e ainda se discute precisamente qual a sua definição. Para alguns especialistas, não é nada mais que uma outra terminologia para a estatística. Há outros que enxergam como um novo paradigma. Não vamos entrar aqui na discussão conceitual, mas focar em entender como é utilizada e suas aplicações no mercado financeiro.

Um cientista de dados tem a missão de analisar e extrair insights a partir dos dados, utilizando a programação. Além disso, utiliza machine learning para criar modelos preditivos. Até alguns anos atrás, esta área era comumente referida como “data mining”, porque o objetivo era literalmente minerar os dados para encontrar insights, padrões, tendências e tomar decisões que ajudassem a área de negócio em questão. De forma geral, podemos estabelecer como pilares de conhecimento dentro da ciência de dados:

1. Fundamentos:
 - a. Manipulação e formatação (data prep), joins, etc.
 - b. Álgebra linear, manipulação de matrizes e vetores
 - c. No Python: pandas e numpy
2. Estatística
 - a. Análise Exploratória de Dados (EDA)
 - b. Conceitos estatísticos: média, mediana, variância, desvio-padrão, histograma, correlação vs. causalidade
 - c. Distribuições
 - d. Testes de hipóteses
 - e. Percentis e outliers
 - f. Teoria das probabilidades
3. Machine Learning
 - a. Modelos de regressão
 - b. Modelos de classificação
 - c. Modelos de clusterização

- d. Avaliação do desempenho de modelos
- e. Text mining/NLP
- f. Deep learning
- 4. Visualização de dados (data viz)
 - a. Ferramentas e bibliotecas de visualização: matplotlib, seaborn, plotly (no Python), ggplot2, plotly (no R)
 - b. Alguma plataforma de criação de dashboards: Tableau, Power BI, Streamlit, etc.
- 5. Big data/Cloud
 - a. Tecnologias tradicionais de dados, ex.: SQL
 - b. Paradigma MapReduce e HDFS
 - c. Tecnologias de computação paralela; Hadoop, Spark, etc.
 - d. Tecnologias de armazenamento e processamento na nuvem, ex.: Databricks
- 6. Ingestão e manipulação de dados
 - a. Princípios de ETL
 - b. Fontes de dados, criação de metadados, *data discovery*
 - c. Manipulação no formato dos dados: redução dimensional; *binning* de variáveis; normalização; análise e remoção de *missings*

Fonte do roadmap original:

<http://nirvacana.com/thoughts/2013/07/08/becoming-a-data-scientist/>

Perceba que fizemos algumas generalizações nos tópicos acima para tornar mais simples a leitura. Um cientista de dados não precisa ter um conhecimento aprofundado sobre **todos** os tópicos acima, mas é importante ter algum contato e entender o funcionamento das técnicas e ferramentas. Normalmente o trabalho de ingestão e processamento dos dados fica a cargo do engenheiro de dados, mas pode acontecer que o cientista de dados atue nesse escopo, dependendo do nível de maturidade de dados que a empresa se encontra.

Como você já deve ter percebido, as “finanças quantitativas” surgiram antes da formação da área que conhecemos hoje como “data science”. Assim, a absorção de conceitos, técnicas e ferramentas da ciência de dados pelo mundo da análise quantitativa é um fenômeno relativamente recente. Isso faz com que muitas vezes o papel do cientista de dados em gestoras de recursos (*assets*) seja confundido com o de quants, e mesmo na descrição das vagas as habilidades solicitadas são intercambiáveis.

De fato, há uma grande interseção entre o que esses dois cargos fazem, e ao longo dos anos veremos uma distinção cada vez mais das suas atividades. A medida que *assets* mais tradicionais (não necessariamente de cunho quantitativo) contratam cientistas de dados, maior se torna a relevância do data science no mercado financeiro.

Dado isso, vale fazer uma breve distinção do trabalho entre esses dois profissionais. Como vimos antes, o cientista de dados carrega a tarefa do “*data mining*”, ou seja, da mineração, descoberta e análise dos dados. Portanto, um cientista de dados pode muito bem trabalhar numa gestora com o objetivo de analisar um volume muito grande de informações, de dados históricos de empresas, instrumentos financeiros, etc, e dessa forma, encontrar distorções no mercado que podem trazer ótimas oportunidades de investimento.

Já o analista quantitativo utilizará todo o seu conhecimento de ciência de dados, estatística, programação e mercado financeiro para desenhar estratégias de investimentos, criar rotinas que geram os *trading signals* (sinais de *trading*), depois precisará testar estas estratégias (*backtesting*), e se elas passarem na avaliação rigorosa, serão implementadas. Um quant, portanto, pode (e deve) utilizar as mesmas ferramentas que o cientista de dados, mas precisará de um arcabouço teórico mais robusto para ser capaz de fazer o *deploy* das estratégias,

saber se essas estratégias fazem sentido e são implementáveis de fato no mercado financeiro. Precisa se familiarizar com os problemas comuns nos backtests, como *overfit*, e os vieses, como viés de sobrevivência (*survivorship bias*), *look-ahead bias*, dentre outros.

Como a união das finanças quantitativas com a ciência de dados é um fenômeno recente, veremos cada vez mais a utilização de ferramentas originalmente desenhadas para o mundo de data science sendo utilizadas em empresas como *assets*, casas de *research*, etc. Um exemplo é a adesão cada vez maior à tecnologias de armazenamento e processamento em nuvem, como Azure e AWS, ou ferramentas para gestão do pipeline de dados e deploy de modelos, como Apache Airflow.

Como entrar no mercado financeiro?

Esta é uma das principais perguntas feitas por quem está se formando agora ou buscando uma transição de carreira para as finanças quantitativas. Vimos anteriormente que não há uma graduação formal em finanças ou mercado financeiro no Brasil, o que torna a entrada no mercado um caminho um tanto nebuloso.

Por isso, vamos trazer aqui algumas possibilidades para te ajudar neste processo. Como já vimos, é fundamental, antes de tudo, conhecer o funcionamento do mercado financeiro. E a melhor forma de garantir esse conhecimento é estando no mercado, vivenciando dia a dia os seus desafios, complexidades e dinâmicas. Portanto, num primeiro momento, acreditamos que a grande prioridade deve ser entrar no mercado financeiro, e a partir disso ir trilhando seu caminho rumo às finanças quantitativas.

Você pode entrar no mercado financeiro através de alguma área mais operacional, como é o caso do back office, e com o tempo ir ganhando experiência em ferramentas analíticas e em programação. Depois de adquirir conhecimento sobre o mercado, pode fazer uma migração para áreas como risco, comercial, front office, tesouraria, dentre outras. Essa é uma das principais portas de entrada por exigir poucos conhecimentos técnicos específicos, mas uma boa capacidade lógica e de raciocínio.

Por causa da grande difusão de conhecimento em programação e ciência de dados, especialmente por causa da internet, é comum que indivíduos recém-formados ou em início de carreira adquiram essas habilidades técnicas antes de ter conhecimento em mercado financeiro. Você pode tirar proveito desse aspecto procurando por algum cargo de tecnologia em empresas como assets, corretoras, bancos, etc., e com o tempo buscar o conhecimento de mercado financeiro a partir da vivência dentro da empresa. Esse é o caso de

analistas, cientistas ou engenheiros de dados que entram no mercado como estagiários ou júnior, e com o tempo adquirem conhecimento de mercado financeiro. Outros cargos de tecnologia, TI, software, por exemplo, se aplicam nesse caso.

A demanda crescente por profissionais de dados é uma boa oportunidade neste sentido, pois mesmo que você entre numa dessas vagas sem trabalhar diretamente com dados de mercado financeiro, pode buscar dentro da própria empresa uma migração para uma área que lida com finanças quantitativas diretamente. Há oportunidades em áreas de suporte ou que não lidam diretamente com as negociações (*trading*) no mercado, como prevenção à fraude, segurança da informação, marketing, compliance, auditoria, risco, comercial, dentre outras.

Um background em economia ou administração pode te dar a possibilidade de entrar no mercado como analista, seja buy-side ou sell-side. Trabalhar no setor de equity research, por exemplo, vai trazer uma boa bagagem não só no funcionamento do mercado financeiro como um todo, como também de setores específicos que o seu time for responsável. Neste sentido, você utilizará dados de diferentes fontes para analisar os indicadores financeiros das empresas cobertas, além de auxiliar na criação dos relatórios.

Uma outra possível entrada é através de alguma das mesas de operações de uma corretora ou banco. É nestas mesas que são negociados uma ampla gama de instrumentos financeiros como ações, commodities, derivativos, renda fixa, dentre outros. Frequentemente, há a necessidade de estruturar e automatizar processos, portanto se você tiver boas habilidades analíticas e de programação, vai levar vantagem nesta área.

Por fim, vamos falar de uma outra porta que tem sido cada vez mais relevante no Brasil, que são os escritórios de agentes autônomos de investimento (AAI). Estes escritórios possuem tanto demandas internas por dados (volume de captação, número de clientes, etc.), como também a necessidade de entender melhor os próprios produtos negociados e dessa forma fazer recomendações mais embasadas. Portanto, é cada vez mais comum que esses escritórios contratem analistas de dados para estruturar essas demandas.

Mesmo que você se torne um assessor de investimentos (que tem perfil comercial), pode depois fazer uma transição de carreira buscando os conhecimentos em estatística/matемática, programação e ciência de dados, e dessa forma se beneficiará do conhecimento que já possui do mercado financeiro.

O cenário atual das finanças quantitativas

Uma pesquisa recente realizada pela SigTech revelou a percepção de gestores de investimentos na Europa, Ásia e América do Norte sobre asset allocation, estratégias quant e mudanças no cenário do uso de ferramentas quantitativas. A pesquisa revelou que há um grande entusiasmo no crescimento da análise quantitativa.

80% dos entrevistados falou que espera que investidores institucionais vão aumentar a alocação em estratégias quantitativas nos próximos 12 meses e 86% acreditam que o número de gestores de portfólio quant (Quant Portfolio Managers) vai aumentar nos próximos 5 anos.

Dados do setor indicam que um a cada cinco hedge funds aplicam processos de investimento quantitativo. Ainda, 22% dos hedge funds do mundo usam processos de investimento **puramente quantitativos**, com cerca de 2% afirmando também utilizar inteligência artificial.

Quando perguntados sobre quais estratégias quantitativas e tipos de ativos vão ser os mais beneficiados em aportes nos próximos 12 meses, os gestores dos hedge funds afirmam que câmbio (foreign exchange) e ações terão as maiores altas, seguidos por juros, volatilidade e estratégias de commodities.

Para ler o relatório completo, acesse:


<https://get.sigtech.com/hedge-fund-research-report-2021>

Link para a matéria:

<https://www.hedgeweek.com/2022/05/05/314332/quant-hedge-funds-increasingly-popular-investors>

Livros

Preparamos uma seleção de livros de várias áreas e subáreas que compõem as finanças quantitativas para você usar como referência na hora de desenvolver as suas habilidades!




Introduction to Statistical Learning

Livro gratuito

Gareth James
Daniela Witten
Trevor Hastie
Rob Tibshirani

Link para o livro: <https://www.statlearning.com/>



Python para Análise de Dados

Wes McKinney



Storytelling com dados

Cole Nussbaumer Knaflic




Estatística Prática para Cientistas de Dados

Peter Bruce
Andrew Bruce



Data Science para Negócios

Foster Provost
Tom Fawcett




Paul Wilmott introduces quantitative finance

Paul Wilmott




Python e Mercado Financeiro

Marco Antonio Leonel Caetano



Frequently asked questions in Quantitative Finance

Paul Wilmott



The man who solved the market


Gregory Zuckerman



Yves Hilpisch


Python for Finance

Yves Hilpisch




Algorithmic Trading: Winning strategies and their rationale

Ernest P. Chan



Quantitative Trading: how to build your own algorithmic trading business

Ernest P. Chan




Advances in Financial Machine Learning

Marcos López de Prado



Machine Learning for Asset Managers


Marcos López de Prado



The book of Alternative Data


Alexander Denev

Saeed Amen



Machine Learning for Algorithmic Trading

Stefan Jansen



Derivatives Analytics with Python

Yves Hilpisch

Para continuar aprendendo

Quant Trading - a history. Canal Patrick Boyle no YouTube

<https://www.youtube.com/watch?v=omgx50jjwPo>

Top 5 Quantitative Hedge Funds

<https://www.youtube.com/watch?v=oU0LcVLM1pc>

How to become a Quant

<https://youtu.be/84n36iPhIFc>

The Past and Future of Quantitative Asset Management - Clifford S.

Asness Managing and Founding Principal AQR Capital Management, LLC

<https://www.aqr.com/-/media/AQR/Documents/Insights/Journal-Article/CFA-PQ-The-Past-and-Future-of-Quantitative-Asset-Management.pdf>

Quem é Markowitz - Blog Pandhora Asset Management

<https://blog.pandhora.com/markowitz/>

The theory of security pricing and market structure -

<https://rodneywhitecenter.wharton.upenn.edu/wp-content/uploads/2014/04/9206.pdf>

Optimization Methods in Finance -

http://web.math.ku.dk/~rolf/CT_FinOpt.pdf

Referências

1. What is Quantitative Finance? Corporate Finance Institute.
<https://corporatefinanceinstitute.com/resources/knowledge/finance/quantitative-finance/>
2. Portfolio Selection - Harry Markowitz -
<https://www.jstor.org/stable/2975974>
3. What is Quantitative Finance?
<https://ghannami.com/what-is-quantitative-finance/>
4. Optimization Methods in Finance -
http://web.math.ku.dk/~rolf/CT_FinOpt.pdf
5. Melgaço, Jorge Henrique Corrêa (2021). *Modelagem do Mercado Financeiro baseado na equação de Black-Scholes e em equações diferenciais estocásticas não-lineares*. CEFET-MG.
6. Muranaga, Jun; Shimizu, Tokiko. Market microstructure and market liquidity. Bank of Japan.
https://www.bis.org/publ/cgfs11mura_a.pdf
7. Hierarchical Risk Parity
<https://hudsonthames.org/an-introduction-to-the-hierarchical-risk-parity-algorithm/>