

Uma Aplicação de Meta-Aprendizagem no Mercado Euro/Dólar

Felipe A. Duarte*

Renato C. Sato†

Ana C. Lorena‡

10 de agosto de 2018

Resumo

Saber quando comprar (ou vender) um ativo demonstra ser uma decisão importante para a obtenção de lucros em mercados financeiros. Entretanto, antes mesmos de se tomar tal decisão, um investidor deve escolher o modelo ideal para o estudo e análise de uma série de dados. Devido a grande quantidade de modelos disponíveis, a escolha de um modelo ideal muitas vezes se torna uma tarefa difícil, principalmente para investidores inexperientes. A meta-aprendizagem é uma ótima ferramenta para auxiliar em tal decisão. Esta ferramenta computacional tem sido empregada em problemas de seleção de algoritmos e, tem apresentado bons resultados na seleção de modelos de estudo de séries temporais. Neste trabalho, buscamos utilizá-la para o estudo e análise de séries temporais, mais especificamente em dados do mercado Euro/Dólar, através de um algoritmo de ranqueamento que classifica e ordena os melhores modelos para o usuário.

Palavras-chave: meta-aprendizagem. séries temporais. seleção de modelos. forex.

1 Introdução

O estudo de séries temporais tem sido uma área de grande interesse desde a década de 1950 e, estudos empíricos tem sido realizados para avaliar um número cada vez maior de algoritmos disponíveis. “Tradicionalmente, os especialistas inspecionam visualmente as características das séries temporais e ajustam os modelos de acordo com seu julgamento” [11].

Entretanto, em mercados financeiros, o sucesso de um investidor depende da qualidade da informação utilizada para auxiliá-lo, e em quão rápido ele consegue chegar a tal decisão [5].

O problema de seleção de modelos para estudo de séries temporais se assemelha ao problema de seleção de algoritmos encontrados em algumas áreas da computação [16]. Com isso, algumas técnicas computacionais podem ser utilizadas para auxiliar investidores na tomada de decisão, dentre elas, a então denominada meta-aprendizagem [18]. Este método consiste em um algoritmo computacional que utiliza de características de problemas passados como conhecimento prévio para resolver problemas futuros.

Alguns trabalhos vem sendo utilizados para realizar tais sugestões, como [8], que apresenta alguns resultados na seleção dentre três modelos computaci-

onais de regressão. [10] e [11] resumem, através de tabelas, os atributos que podem ser retirados dos dados afim de se obter as melhores descrições dos mesmos. [15] realizam dois estudos de caso, destacando-se a aplicação de um método de ranqueamento de algoritmos, ou seja, um método que atribui pesos para os melhores estimadores.

Entretanto não foram encontrados trabalhos com aplicação direta de tal algoritmo em dados do mercado de câmbio. O mercado de câmbio (ou então *forex*), é um dos maiores mercados mundiais e movimenta cerca de dois trilhões de dólares por dia [19]. Este é um mercado muito líquido devido ao alto nível de participação, o que oferece uma boa oportunidade de lucros quando os seus ativos apresentam uma tendência forte [13].

Portanto, propomos aplicar um algoritmo de meta-aprendizagem em dados do mercado de câmbio, mais especificamente nos dados do mercado Euro/Dólar, com o intuito de auxiliar investidores na tomada de decisão para a seleção de um modelo. O presente trabalho traz alguns resultados parciais desenvolvidos durante a pesquisa para obtenção do título de mestre do primeiro autor.

A seção 2 apresentará um pouco da história, vantagens e desvantagens de se negociar no mercado de câmbio. No Capítulo 3 será encontrado algumas definições e elementos de séries temporais, assim como,

*felipeaduart@gmail.com

†rcsato@unifesp.br

‡aclorena@unifesp.br

os modelos selecionados para estudo das mesmas. A definição de meta-aprendizagem e de seus elementos poderá ser encontrada no Capítulo 4. A metodologia juntamente com alguns resultados parciais são encontrados no Capítulo 5, enquanto o Capítulo 6 traz propostas de atividades futuras.

2 O mercado *Forex*

No início da Segunda Guerra Mundial iniciou-se uma discussão sobre um novo modelo econômico a ser adotado. A Conferência de *Bretton Woods* de 1944, estabeleceu o dólar americano como uma moeda padrão e as demais moedas tinham suas flutuações fixadas em 1% no valor do dólar.

Tal sistema se manteve até a década de 70 quando, em 1971, o então presidente dos Estados Unidos, Richard Nixon, abandonou a conversão do dólar em ouro, fazendo com que as moedas passassem a flutuar livremente. Entretanto, apenas em 1973 que o sistema dado pelos Acordos de *Bretton Woods* foi substituído pelo regime baseado em câmbio flutuante, que está em vigor até hoje.

O mercado de câmbio (ou *forex*) é um dos mais líquidos e, economicamente, importante mercado no mundo, porém, um dos mais obscuros com respeito à informação de suas transações [6]. Mais de U\$3,7 trilhões de dólares são negociados diariamente neste mercado, impactando no desenvolvimento e na inflação de vários países, principalmente nas taxas de importação e exportação. Tal mercado também pode ser operado de forma online, garantindo segurança e sigilo em suas transações.

[1] destaca algumas vantagens de se trabalhar com o mercado *forex* como:

- operação entre os países 24hrs por dia;
- o volume de negociações diárias é muito superior ao volume de mercados capitais;
- as taxas de câmbio dos pares são mais afetadas por políticas e intervenções monetárias do que as ações e títulos;
- intervenções dos bancos centrais normalmente oferecem um impacto positivo no nível e na volatilidade das taxas de câmbio.

No mercado *forex*, bancos centrais e outras autoridades financeiras são os participantes mais influentes; suas ações afetam tanto os retornos quanto a volatilidade das cotações, visando atingir um valor alvo [7].

[4] mostram que os *spillovers* de volatilidade aumentam em períodos de incerteza do mercado, especialmente durante a crise financeira de 2007-2008. [1] demonstram que os *spillovers* negativos estão ligados à crise financeira européia, enquanto os *spillovers* positivos estão correlacionados com a

crise *subprime*, diferentes políticas monetárias entre os principais bancos centrais mundiais e a evolução nos mercados de commodities.

3 Modelos Utilizados

Nesta seção, discutiremos alguns modelos encontrados na literatura utilizados para análise e previsões de séries temporais. Os modelos selecionados são, em sua maioria, modelos lineares e de baixo custo computacional, podendo ser encontrados em bibliotecas como *forecast* do programa R.

[14] relata que modelos lineares são bem utilizados na literatura apesar dos dados financeiros reais apresentarem muitas características não lineares. Os modelos lineares são preferíveis por sua simplicidade, abordagem adequada e por serem matematicamente convenientes.

3.1 Modelos Autorregressivos Integrados e de Médias Móveis

Um processo estocástico é dito ser autorregressivo e de médias móveis de ordem (p, q) e denotado por $ARMA(p, q)$ se atender à seguinte equação:

$$X_t - \mu = \phi_1(X_{t-1} - \mu) + \dots + \phi_p(X_{t-p} - \mu) + \varepsilon_t - \theta_1\varepsilon_{t-1} - \dots - \theta_q\varepsilon_{t-q} \quad (1)$$

onde $\varepsilon_t \sim RB(0, \sigma^2)$ e, a média do processo é μ .

Se $\Delta^d X_t$ for estacionário, dizemos que X_t é integrado de ordem d e escrevemos $X_t \sim I(d)$. Mais especificamente temos: Se $\Delta^d X_t \sim ARMA(p, q)$ dizemos que X_t segue um modelo $ARIMA(p, d, q)$: autorregressivo integrado e de médias móveis de ordem (p, d, q) , ou seja,

$$\phi(B)\Delta^d X_t = \theta_0 + \theta(B)a_t. \quad (2)$$

O ajuste de um modelo $ARIMA(p, d, q)$ pode ser realizado através da metodologia Box-Jenkins [2] que consiste em três etapas fundamentais: identificação, estimação e diagnóstico.

Para o processo de identificação, pode ser utilizada a análise dos correlogramas do f.a.c. e f.a.c.p. [9], traz um resumo do comportamento de tais gráficos para cada um dos processos da família $ARIMA(p, d, q)$. Deve-se verificar se há necessidade de diferenciar a série original a fim de se ajustar um modelo $ARMA$ na série diferenciada. Após a estacionaridade da série por meio das diferenciações, o usuário deve estimar os parâmetros p e q utilizando os correlogramas das f.a.c. e f.a.c.p.

Após a identificação dos modelos, realiza-se a estimação dos parâmetros através de métodos dos momentos, mínimos quadrados ou máxima verossimilhança. Na etapa de diagnóstico, verifica se eles representam bem ou não os dados. Para isso, uma estratégia muito útil é a verificação dos resíduos;

se os mesmos se assemelharem a um ruído branco, então o modelo representa bem os dados. Também pode-se utilizar o teste de Box-Pierce-Ljung para verificar as autocorrelações dos resíduos estimados.

3.2 Modelos de Médias Móveis Simples

Os modelos de médias móveis simples calcula a média aritmética dos últimos k dados para estimar os seus dados futuros. A constante k é denominada janela de previsão do modelo. O modelo, assim como a previsão dos dados futuros, é dada pela seguinte fórmula:

$$Y_t = \frac{Y_{t-1} + Y_{t-2} + \dots + Y_{t-k}}{k}. \quad (3)$$

3.3 Modelos de Suavização Exponencial

Os modelos de suavização exponencial recebem este nome por serem ajustados com pesos decrescentes para valores passados com decaimento exponencial. Nos modelos de **suavização exponencial simples (SES)**, proposto por [3], o parâmetro α , que deve ser escolhido entre 0 e 1, controla a extensão do ajuste e é atualizado, minimizando os erros em um conjunto de validação:

$$\hat{Y}_{t+1} = \alpha Y_t + (1 - \alpha)^t \hat{Y}_t \quad (4)$$

onde \hat{Y}_{t+1} é a previsão para o período $t + 1$; α o parâmetro constante de suavização que deve ser selecionado entre zero e um; Y_t o valor atual observado; \hat{Y}_t o valor previsto para o valor atual.

Nos casos em que a série temporal apresenta tendência linear, recomenda-se a utilização da **suavização exponencial de Holt (SEH)**. Este método também é conhecido como suavização exponencial dupla por tratar da tendência simultaneamente a série. A sua função de previsão é dada por:

$$\begin{aligned} \hat{Y}_{t+n} &= L_t + nT_t, \text{ onde} \\ L_t &= \alpha Y_t + (1 - \alpha)(L_{t-1} + T_{t-1}), \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \end{aligned} \quad (5)$$

em que L_t é o nível esperado da série no tempo t e T_t é a tendência esperada para os n períodos futuros. O método de Holt utiliza de dois parâmetros α e β denominados constantes de suavização que devem ser selecionados entre 0 e 1.

Se a série, além de apresentar tendência, também apresentar sazonalidade, o método de suavização exponencial recomendado é uma expansão do método de Holt e é apresentada por [22], denominada **suavização exponencial de Holt-Winters (SEHW)**.

O método de Holt-Winters multiplicativo admite o fator sazonal como multiplicativo e a tendência

como aditivo, ou seja:

$$\begin{aligned} Y_t &= L_t S_t + T_t + \epsilon_t, \text{ onde} \\ L_t &= \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + T_{t-1}); \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}; \\ S_t &= \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \end{aligned} \quad (6)$$

onde α, β, γ são as constantes de suavização que devem ser selecionados entre 0 e 1; S_t é o fator sazonal; T_t o fator de tendência; L_t é o fator nível; s é o período da série.

Já o método Holt-Winters para efeitos sazonais aditivos é preferível para séries que a sazonalidade independe do nível. Sendo assim, o modelo é dado por:

$$\begin{aligned} Y_t &= L_t + S_t + T_t + \epsilon_t, \text{ onde} \\ L_t &= \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}); \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}; \\ S_t &= \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \end{aligned} \quad (7)$$

3.4 Máquinas de Vetores de Suporte

Apresentada por [21], os algoritmos de vetores suporte demonstram ser uma ferramenta muito útil tanto para classificação quanto para regressão e consiste na resolução de um problema de otimização convexa. De uma forma geral, o problema ϵ -SV, dado por [21], tende a ajustar uma curva $f(x)$ que tenha no máximo ϵ desvios dos dados alvo y_i .

O problema de otimização convexa dos SVMs é dado pelo seguinte problema dual:

$$\begin{aligned} \max \quad & -\frac{1}{2} \sum_{i,j=1}^L (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)k(x_i, x_j) \\ & - \epsilon \sum_{i=1}^L (\alpha_i + \alpha_i^*) + \sum_{i=1}^L y_i (\alpha_i - \alpha_i^*) \\ \text{s.t.} \quad & \sum_{i=1}^L (\alpha_i - \alpha_i^*) = 0 \\ & \alpha_i, \alpha_i^* \in [0, C]; \end{aligned} \quad (8)$$

O produto interno $\langle \Phi(x_i), \Phi(x_j) \rangle$ pode ser computado por uma função denominada **kernel** e é denotada por $k(x_i, x_j)$. Desde que se tenha conhecimento do resultado de $k(x_i, x_j)$ não há necessidade de calcular $\Phi(x)$ explicitamente. Isso reduz o problema de dimensionalidade do algoritmo, reduzindo o custo computacional do mesmo. O problema dual generalizado para os casos linear e não linear é dado pela Equação 8.

4 Meta-Aprendizagem

O termo meta-aprendizagem no contexto de séries temporais foi primeiramente utilizado, segundo [11], em [15] e é considerado um termo para se referir ao conhecimento adquirido automaticamente para seleção de modelos de previsão em séries temporais.

A meta-aprendizagem surgiu para auxiliar na escolha de algoritmos para um problema dado de forma a automatizar o processo de aquisição de conhecimento empírico. Como o problema de seleção de modelos para estudo de séries temporais se assemelha a problemas de seleção de algoritmos, algumas técnicas de meta-apredizagem podem ser utilizadas para tal fim [16].

[10] define meta-aprendizagem como “o estudo de métodos que exploram o meta-conhecimento objetivando uma melhora ou a obtenção de soluções de aprendizado de máquinas mais eficientes.” Eles também destacam o uso de tal ferramenta computacional nas recomendações de técnicas de otimização, análise de séries temporais, comparação de algoritmos de aprendizado de máquinas, entre outros.

O Problema de Seleção de Algoritmo (PSA), que foi originalmente proposto por [18], propõe a existência de uma relação entre características dos problemas e dos algoritmos que podem ser utilizados para a realização da sugestão de modelos. O PSA proposto por é composto por 4 componentes principais:

- **O espaço problema:** uma grande coleção de problemas de natureza multi-dimensional.
- **O espaço atributo:** espaço constituinte de vetores que armazenam as características dos problemas trabalhados.
- **O espaço algoritmo:** espaço que armazena os algoritmos utilizados no algoritmo.
- **O espaço de medida de performance:** espaço composto por diferentes medidas de performance dos algoritmos.

Entretanto, o próprio procedimento de seleção é uma classe específica de seleção de algoritmos, escolhida com parâmetros livres e, esses parâmetros são então escolhidos de modo a satisfazer (assim como podem) os objetivos do problema de seleção. A abordagem mais simples é testar cada algoritmo e selecionar os que tiveram melhores performance. No entanto, apesar de ser uma abordagem simples, ela pode ser muito custosa para um número grande de modelos candidatos.

Para a resolução de um PSA, destacam-se cinco etapas fundamentais que o usuário deve seguir para encontrar uma boa solução: formulação, existência, unicidade, caracterização e cálculo. Na etapa de formulação, deve-se determinar as sub-classes dos problemas e dos mapeamentos que serão utilizados na meta-aprendizagem. Para existência, a meta-aprendizagem tenta responder se o algoritmo com a melhor performance existe. Unicidade é apresentar que tal algoritmo é o único com esta performance. Na caracterização, o algoritmo deve verificar quais características descrevem da melhor forma os problemas propostos, selecionando os melhores mapeamentos e atributos. Cálculo é a etapa de verificação

do modelo, onde o usuário deve verificar quais dos métodos apresentam os melhores resultados.

Em aprendizagem de máquinas usuais, o sistema é composto por duas etapas: a fase de treinamento e a de teste. No treinamento, o meta-aprendiz adquire conhecimento dos exemplos armazenados no banco de dados. Este conhecimento associa os atributos do problema às performances dos algoritmos candidatos [16]. Na etapa de teste, o meta-aprendiz extrai os atributos dos novos problemas e os utiliza para sugerir um algoritmo candidato.

4.1 Elementos da Meta-Aprendizagem

São dois os elementos fundamentais para o desenvolvimento de um algoritmo de meta-aprendizagem: a base de dados e o meta-aprendiz. A base de dados armazena os meta-atributos e os problemas utilizados na fase de treinamento, juntamente com a performance dos algoritmos candidatos.

Os meta-atributos são características extraídas dos conjuntos de dados que fornecem informações sobre a performance futura dos conjuntos de dados das técnicas investigadas. [10] fornece os principais grupos de características que poderão ser extraídas dos conjuntos de dados:

- *Atributos simples, estatísticos e de informação teórica:* são medidas de fácil extração, normalmente descrevendo medidas estatísticas centrais, ou valores básicos como número de atributos/classes, ou até mesmo medidas de entropia e informações mútuas.
- *Atributos baseados em modelos:* características próprias dos modelos pesquisados, como por exemplo número de folhas, nós ou máximo de caminhos de uma árvore de decisão.
- *Landmarking:* algoritmos fáceis e rápidos para extração de atributos de precisão e *recall* obtidos.

[11] utilizaram de 23 atributos que são categorizados em quatro grupos distintos. Dois desses grupos são as medidas de estatísticas gerais/centrais e as medidas de autocorrelação.

O meta-aprendiz implementa a meta-aprendizagem escolhida através da aquisição de conhecimento, na etapa de treinamento, a ser utilizado para a sugestão dos modelos candidatos. O meta-aprendiz é a etapa responsável em extrair atributos dos dados que serão estudados e, através de comparação dos mesmos, encontrar o algoritmo com a melhor performance para tal problema.

4.2 Recomendações de algoritmos

[20] apresenta quatro formas de recomendação de algoritmos em seu trabalho: o melhor algoritmo no conjunto; um subconjunto de algoritmos; ranqueamento de algoritmos; estimação de performance dos algoritmos. O ranqueamento apresenta uma lista ordenada de algoritmos de forma que o usuário possa identificar qual dos algoritmos apresenta uma melhor precisão.

O ranqueamento de algoritmos recomendados para um novo conjunto de dados é dado pelas seguintes etapas:

1. um novo problema é apresentado ao algoritmo;
2. meta-atributos são extraídos deste problema;
3. um algoritmo de classificação é aplicado afim de se identificar problemas similares;
4. para cada um dos problemas similares encontrados aplica-se os algoritmos estudados e suas performances são medidas através de ferramentas próprias;
5. ranqueia-se tais modelos utilizando as performances medidas.

Existem também mais formas de ranqueamento tais como ranqueamento médio, ranking de pontuação e ranking vencedor [20].

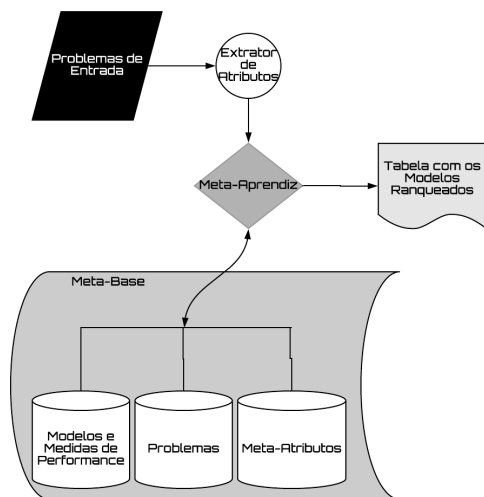


Figura 1 – Fluxograma da meta-aprendizagem utilizada.

Fonte: Autor.

5 Metodologia

5.1 Dados

Optou-se em trabalhar com dados do mercado euro/dólar (EUR/USD) por se tratar de um mercado

de grande negociação em *forex* (aproximadamente 30% [13]). Tomamos os dados diários do período de 1 de janeiro de 2010 a 31 de dezembro de 2017, por se tratar de um período atual e pela instabilidade econômica apresentada neste período (pós-crise de 2007/2008 e crise do euro nos anos de 2013/2014).

Os dados foram divididos em dados de treinamento e dados de teste. Os dados de treinamento representam, aproximadamente, 75% dos dados coletados (aproximadamente 1576 dados diários) e compreende o período de 1 de janeiro de 2010 a 15 de janeiro de 2016, enquanto o restante (528 dados diários) foram armazenados para testes.

Os dados de treinamento foram separados em pequenos subconjuntos que foram utilizados para estimação dos modelos e cálculo da medida de erro de estimação, formando assim, o espaço problema da meta-aprendizagem. Dos mesmos foram extraídos as características utilizadas para comparação do meta-aprendiz, criando-se o espaço atributo.

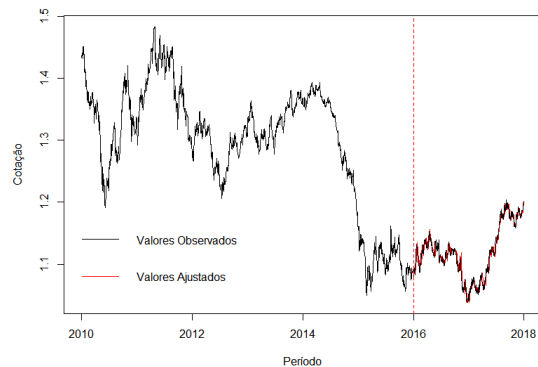


Figura 2 – Gráfico dos dados utilizados.

Fonte: Autor.

Durante o período de 2014 a 2015, nota-se uma grande desvalorização do euro com relação ao dólar. Isso se deve a dois fatores fundamentais: a primeira é a diferença entre a política dos grandes bancos centrais (*Fed*, BCE e Banco do Japão); a segunda, devido a queda dos preços de commodities, que influenciou na queda da inflação e da taxa de juros [1].

5.2 O algoritmo aplicado

A meta-aprendizagem utilizada foi desenvolvida em duas etapas principais: criação da meta-base e teste da meta-aprendizagem. Para a criação da meta-base, os dados de treinamento foram tomados e separados em sub-conjuntos de 30 dados diários que foram utilizados para estimação dos modelos propostos e extração de atributos.

O algoritmo foi desenvolvido no programa R [17], devido aos seus pacotes estatísticos e às suas funções para um ajuste automatizado dos modelos propostos.

Para a estimação dos modelos SVMs, como os mesmos dependem do *kernel* utilizado, eles podem apresentar dois (C, ε) ou muitos mais (dependendo do *kernel* escolhido) parâmetros para serem ajustados. Entretanto, o comando para auto-ajuste desses parâmetros demonstrou-se muito custoso.

Visando contornar tal problema, optamos pela aplicação de uma meta-heurísticas para a seleção dos parâmetros. Meta-heurísticas tem sido largamente utilizadas para cálculo e estimação de parâmetros devido à facilidade de programação e baixo custo computacional. A meta-heurística selecionada é denominada Busca Local Iterada (*Itered Local Search - ILS*).

A ILS, é uma “construção iterativa de uma seqüência de soluções geradas por heurística incorporada, levando a soluções muito melhores do que se alguém usasse ensaios aleatórios repetidos dessa heurística” [12]. Sua estratégia é bem simples, encontrar um ótimo local e, através de uma perturbação, encontrar um segundo ótimo local melhor do que o anterior.

Para a composição da meta-base, também se faz necessário o banco de dados com as medidas de atributos dos dados de treino. Os atributos retirados para esta pesquisa foram baseadas nos atributos dados por [11] e são resumidos na tabela 1.

Tabela 1 – Atributos utilizados na meta-aprendizagem.

<i>Estatísticas gerais</i>
desvio padrão da série
assimetria e curtose da série
primeiro coeficiente de autocorrelação parcial
<i>medidas centrais</i>
mín., média, média aparada, mediana e máx.
intervalo simples e intervalo interquartil
pontos de inflexão

O meta-aprendiz, é então, a etapa do algoritmo reponsável por tomar o conjunto de dados de entrada, ou seja, os dados não utilizados na construção da meta-base; extrair os seus atributos e os comparar com os atributos dos conjuntos da meta-base, tomando o conjunto de dados da meta-base com a menor distância euclidiana.

Ao encontrar tal conjunto, o meta-aprendiz calcula e apresenta uma lista ordenada pelo erro de predição (dada na etapa de treinamento) com os melhores modelos.

6 Resultados Parciais

Propomos então, a utilização de um algoritmo de meta-aprendizagem para sugestão de modelos para estudo e análise de séries temporais no mercado euro/dólar.

Para realização de testes do algoritmo de meta-aprendizagem, foram utilizados os dados de teste que constituem de 528 dados diários do período de 16 de janeiro de 2016 a 29 de dezembro de 2017. Tal conjunto foi subdividido em subconjuntos menores de séries temporais que, individualmente, representam novos problemas para o meta-aprendiz.

Tabela 2 – Número de vitórias, pontuação e média dos ranqueamentos.

	Linear	RBF	ARIMA
Vencedor	244	98	38
Pontuação	1977	1574	1349
Média	3.99	3.17	2.72
	GARCH	MA	Suavização
Vencedor	0	40	76
Pontuação	55	1070	1415
Média	0.11	2.16	2.85

Como pode-se observar da tabela 2, o modelo SVM com *kernel* Linear ganhou, com larga vantagem, a maioria das sugestões apresentadas pelo nosso algoritmo.

Podemos observar as estimações dadas pelos modelos sugeridos na figura 3. Observamos que as previsões realizadas pelos modelos sugeridos acompanha o comportamento tendencioso dos dados reais, o que indica boas estimações. A raiz do erro quadrático médio, medida de precisão utilizada neste trabalho, das previsões realizadas é de aproximadamente 0.007858.




Figura 3 – Gráfico da estimacão dada pelas sugestões da meta-aprendizagem.

Fonte: Autor.

Considerações finais

Propomos então, uma aplicação de um algoritmo de met-aprendizagem para o estudo e análise de séries temporais. O algoritmo de ranqueamento sugere o SVM Linear como o melhor modelo a ser utilizado nestes dados mesmo não dispensando os demais modelos em algumas janelas de análise.

Como resultado inicial, a aplicação de meta-aprendizagem demonstrou-se promissora para sugestão de modelos para o estudo de séries temporais. Entretanto, mais alguns testes devem ser realizados para se confirmar a contribuição do algoritmo para o estudo de tal tipo de dado. O uso de um modelo como *baseline*, isto é, como parâmetro de comparação é um dos testes que devemos realizar futuramente, assim como mudanças no tamanho dos subconjuntos de treinamento e, talvez na janela de previsão.

Este trabalho demonstra-se motivador ao estender as ferramentas utilizadas para a análise de séries temporais. Para trabalhos futuros, poderá ser acrescentado modelos híbridos na competição de melhor modelo ou, até mesmo, uma adaptação de um algoritmo de meta-aprendizagem para a seleção e sugestão de modelos de estudo de séries temporais híbridos.

Referências

- [1] J. Baruník, E. Kočenda, and L. Vácha. Asymmetric volatility connectedness on the forex market. *Journal of International Money and Finance*, 77:39–56, oct 2017. Citado 2 vezes nas páginas 2 e 5.
- [2] G. Box, G. M. Jenkins, and G. Reinsel. *Time Series Analysis: Forecasting & Control (3rd Edition)*. Prentice Hall, 1994. Citado na página 2.
- [3] R. G. Brown. *Statistical Forecasting for Inventory Control*. McGraw-Hill Book Co., Inc., 1959. Citado na página 3.
- [4] V. Bubák, E. Kočenda, and F. Žikeš. Volatility transmission in emerging european foreign exchange markets. *Journal of Banking & Finance*, 35(11):2829–2841, nov 2011. Citado na página 2.
- [5] R. C. Cavalcante, R. C. Brasileiro, V. L. Souza, J. P. Nobrega, and A. L. Oliveira. Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, 55:194–211, aug 2016. Citado na página 1.
- [6] M. Cerrato, N. Sarantis, and A. Saunders. An investigation of customer order flow in the foreign exchange market. *Journal of Banking & Finance*, 35(8):1892–1906, aug 2011. Citado na página 2.
- [7] Y.-L. Chen and Y.-F. Gau. Foreign exchange market intervention and price discovery. *Journal of the Japanese and International Economies*, 38:214–227, dec 2015. Citado na página 2.
- [8] R. M. de Souza. Meta-aprendizado para a seleção automática de modelos de séries temporais. mthesis, Universidade Federal de Pernambuco, Aug. 2010. Citado na página 1.
- [9] R. S. Ehlers. Análise de séries temporais. Disponível em: <http://www.icmc.usp.br/ehlers/stemp/stemp.pdf>. Acesso em: 28 abr 2018., 2009. Citado na página 2.
- [10] L. P. Garcia, A. C. de Carvalho, and A. C. Lorena. Noise detection in the meta-learning level. *Neurocomputing*, 176:14–25, feb 2016. Citado 2 vezes nas páginas 1 e 4.
- [11] C. Lemke and B. Gabrys. Meta-learning for time series forecasting and forecast combination. *Neurocomputing*, 73(10-12):2006–2016, jun 2010. Citado 4 vezes nas páginas 1, 3, 4 e 6.
- [12] H. R. D. Lourenço, O. C. Martin, and T. Stutzle. Iterated local search. *SSRN Electronic Journal*, 2001. Citado na página 6.
- [13] J. Norris, T. Bell, and A. Gaskill. *Mastering the Currency Market: Forex Strategies for High and Low Volatility Markets*. McGraw-Hill Education, 2009. Citado 2 vezes nas páginas 1 e 5.
- [14] R. Pincak. The string prediction models as invariants of time series in the forex market. *Physica A: Statistical Mechanics and its Applications*, 392(24):6414–6426, dec 2013. Citado na página 2.
- [15] R. Prudêncio and T. Ludermit. Using machine learning techniques to combine forecasting methods. In *Lecture Notes in Computer Science*, pages 1122–1127. Springer Berlin Heidelberg, 2004. Citado 2 vezes nas páginas 1 e 3.
- [16] R. B. Prudêncio and T. B. Ludermit. Meta-learning approaches to selecting time series models. *Neurocomputing*, 61:121–137, oct 2004. Citado 2 vezes nas páginas 1 e 4.
- [17] R Core Team. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2017. Citado na página 5.
- [18] J. R. Rice. The algorithm selection problem. In *Advances in Computers*, pages 65–118. Elsevier, 1976. Citado 2 vezes nas páginas 1 e 4.
- [19] N. Shahbazi, M. Memarzadeh, and J. Gryz. Forex market prediction using NARX neural

- network with bagging. *MATEC Web of Conferences*, 68:19001, 2016. Citado na página 1.
- [20] M. Tripathy, , and A. Panda. A study of algorithm selection in data mining using meta-learning. *Journal of Engineering Science and Technology Review*, 10(2):51–64, jun 2017. Citado na página 5.
- [21] V. N. Vapnik. *The Nature of Statistical Learning Theory*. Springer New York, 2000. Citado na página 3.
- [22] P. R. Winters. Forecasting sales by exponentially weighted moving averages. *Management Science*, 6(3):324–342, apr 1960. Citado na página 3.