

Proposal and Implementation of Machine Learning and Deep Learning Models for Stock Markets

Prof. Dr. Adriano C. Machado Pereira
UFMG DCC
adrianoc@dcc.ufmg.br

Eduardo Jabbur Machado
Doutorando CEFET-MG MMC
ejabbur@gmail.com

Renato Oliveira
Mestrando UFMG DCC
7renato@outlook.com

Estrutura do Trabalho

- 1) Introdução
- 2) Objetivo
- 3) Fundamentação Teórica
- 4) Metodologia
- 5) Simulação e Resultados
- 6) Conclusão
- 7) Trabalhos Futuros
- 8) Referências

Definição do Problema de Pesquisa

Tratamento dos Dados:

Qual a melhor forma e ou técnicas de ciências dos dados para selecionar, preparar e analisar os dados de séries temporais de ações negociados em bolsa de valores?

Modelo de Previsão:

Como configurar, treinar, medir, combinar e selecionar modelos de classificação com o objetivo de prever tendências de retornos?

Modelo de Operação:

De que maneira podemos interpretar a série de previsões dos modelos de modo a criar estratégias de operação no mercado buscando taxas de retornos satisfatórias e que superem valores de referências?

Objetivo da Pesquisa

1. Implementar 3 algoritmos de aprendizado de máquina para atuarem como modelos de previsão de tendências;
2. Modelar uma estratégia de operação para a execução de gatilhos com ordens de compra e venda no mercado financeiro; e
3. Comparar o desempenho dos modelos de previsão e da estratégia de negociação em à relação:
 - Taxa de Precisão
 - Ganho Financeiro
 - Custo Operacional

Fundamentação Teórica

Medidas de Desempenho:

- Precisão
- Acurácia
- *Recall*
- *F1-score*
- Especificidade

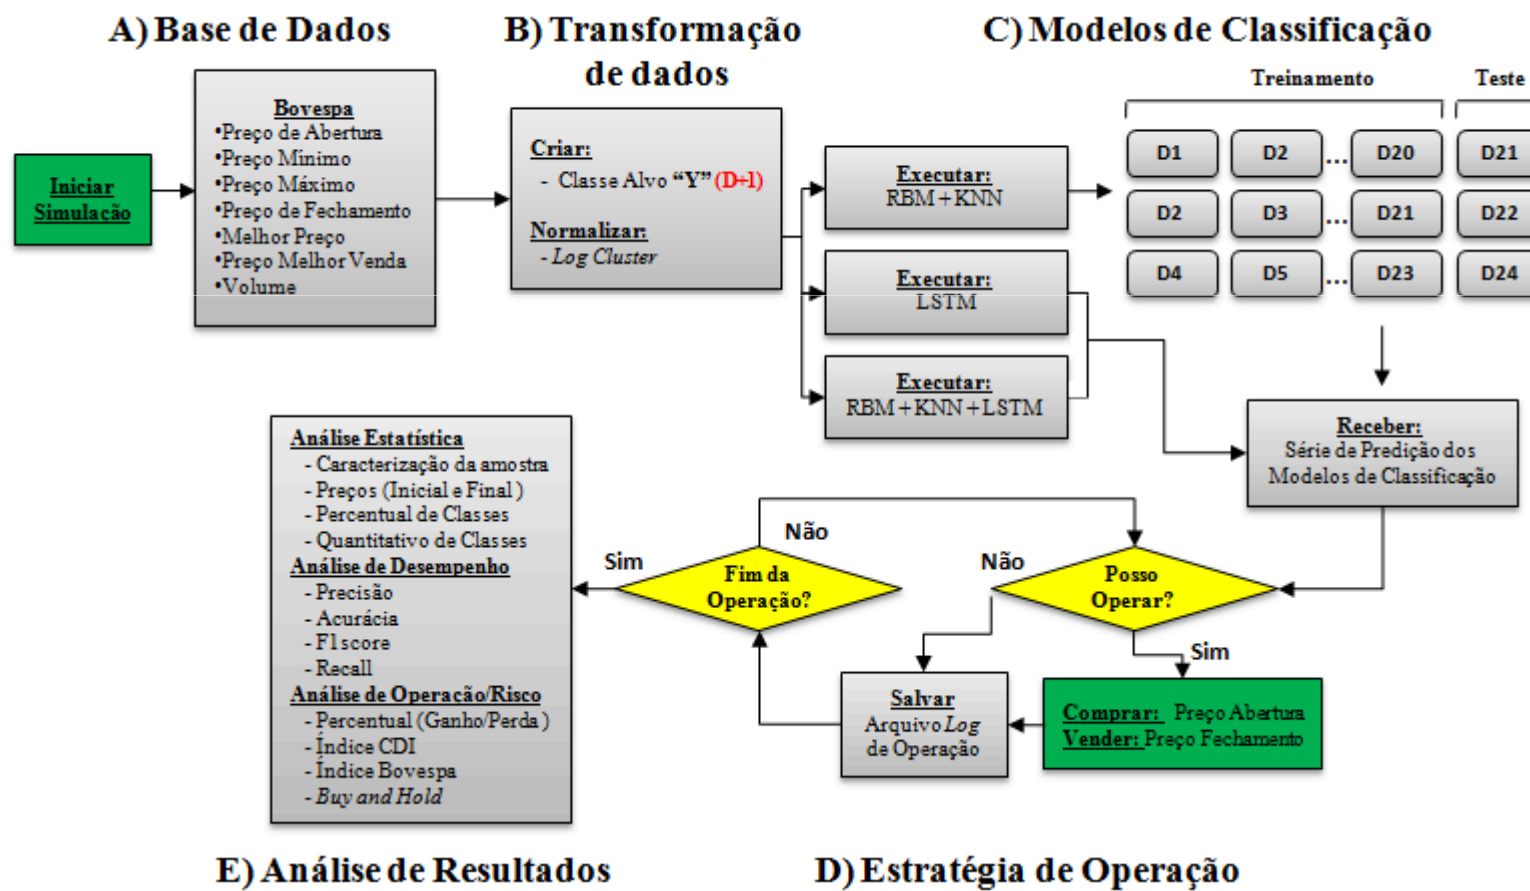
Medidas de Risco:

- Volatilidade *Downside*
- Índice *Sharpe*
- Índice *Sortino*

Modelos de Aprendizado de Máquina:

- *K-Nearest Neighbor (KNN)*
- *Máquina Restrita de Boltzmann (RBM)*
- *Long-Short Term Memory (LSTM)*

Metodologia



Simulação e Resultados

Table 1: Configuração dos algoritmos *LSTM*, *KNN* e *RBM*.

LSTM	KNN	RBM
Quantidade de Camadas = 4	Número de Vizinhos = 5	Número de Componentes = 4
Camada 1 = Batch Normalization	Tamanho da Folha = 30	Número de Épocas = 200
Camada 2 = 125 unidades	Ponderação de Pesos = Uniforme	Taxa de Aprendizado = 0,01
Camada 3 = 75 unidades	Distância entre pontos = Euclidiana	Inicialização = Determinístico
Regularizador L1 e L2 = 0,005		
Função de Ativação = Sigmóide		
Otimizador = Adagrad		
Função de Perda = Binary Cross Entropy		
Número de Épocas = 200		
Tamanho do Batch = 100		
Conjunto de Validação = 20		

Simulação e Resultados

Table 2: Indicadores Comparativos de *Baseline*

Período Inicial	05/01/2015
Período Final	28/12/2015
Dias úteis de avaliação	243
Taxa do CDI	12,5%
Taxa SELIC	12,52%
Índice IBOVESPA	-12,32%
Índice IGPM	10,08%
Custo Operacional	25,00%

Simulação e Resultados

Table 4: Valor de Mercado e Variação dos Códigos de Ativos entre Janeiro de 2015 e 2018.

Ativo	Nome	Setor	2015	2018	Variação
BBSA3	Banco do Brasil	Financeiro	R\$ 22,58	R\$ 32,93	45,84%
USIM5	Usinas Siderúrgicas SA	Mineração	R\$ 4,75	R\$ 10,03	111,16%
PETR4	Petróleo Brasileiro SA	Óleo e Gás	R\$ 9,14	R\$ 16,55	81,07%

Simulação e Resultados




Figure 2: Série de Preço de Fechamento Original e Normalizada de 243 dias úteis.

Simulação e Resultados

Table 5: Caracterização da Amostra

Ativo	BBAS3	PETR4	USIM5
Preço Inicial	R\$ 22,58	R\$ 9,14	R\$ 4,75
Preço Final	R\$ 14,98	R\$ 6,70	R\$ 1,58
Classe0 Real (%)	57,61%	55,97%	62,14%
Classe1 Real (%)	42,39%	44,03%	37,86%
Qtde Classe0 Real	140	136	151
Qtde Classe1 Real	103	107	92
BuyAndHold (%)	-33,66%	-26,70%	-66,74%

Simulação e Resultados

Table 3: Resultados de 243 dias úteis do período de 05/01/2015 a 31/12/2015.

Modelos	RBM + KNN			LSTM			RBM + KNN + LSTM		
	PETR4	USIM5	BBAS3	PETR4	USIM5	BBAS3	PETR4	USIM5	BBAS3
Ativos									
Ganho Máximo (%)	10,99	9,6	7,61	8,04	8,45	7,61	5,34	8,45	7,61
Perda Máxima (%)	-7,53	-10,94	-5,29	-6,94	-15,35	-6,81	-5,95	-10,94	-5,02
Perda (%)	-96,42	-122,14	-78,27	-111,59	-138,7	-154,59	-12,25	-58,92	-46,01
Ganho (%)	122,09	147,28	107,85	111,05	90,01	126,84	44,47	54,06	57,94
Qtde Perda	39	38	43	51	43	65	6	16	23
Qtde Ganho	50	42	37	43	30	49	17	15	18
Qtde Total	89	80	80	94	73	114	23	31	41
Qtde Classe0	153	162	162	148	169	128	219	211	201
Qtde Classe1	89	80	80	94	73	114	23	31	41
Lucro Líquido (%)	25,66	25,14	29,58	-0,54	-48,69	-27,75	32,22	-4,87	11,93
Lucro Bruto (%)	32,08	31,43	36,98	-0,68	-60,86	-34,69	40,28	-6,09	14,91
Precisão (%)	56,18	52,50	46,25	46,00	41,00	43,00	51,09	46,75	44,63
Acuracia (%)	60,33	63,64	54,96	53,00	56,00	51,00	56,67	59,82	52,98
F1score (%)	51,02	48,84	40,44	43,00	36,00	45,00	47,01	42,42	42,72
Recall	46,73	45,65	35,92	40,00	33,00	48,00	43,37	39,33	41,96
Especificidade	71,11	74,67	69,06	62,00	71,00	53,00	66,56	72,84	61,03
Índice Sharpe	2,48	4,46	1,87	-0,49	-19,31	-3,43	6,16	-2,58	1,16
Índice Sortino	4,18	6,94	3,48	-0,83	-30,03	-6,39	10,38	-4,01	2,17

Conclusão

- Não é possível garantir percentual de lucro líquido viável e acima dos *baselines* de mercado, sempre que o modelo de previsão de tendência encontrar uma precisão acima de 50%;
- O modelo previsão de Tendência (RBM + KNN) encontrou para os códigos de ativos PETR4, USIM5 e BBAS3 percentual de lucro líquido de 25,66% 25,14% e 29,58% para um período de 243 dias; e

Trabalhos Futuros

- **Implementar** uma estratégia de operação alvo de 1%, 2% e etc;
- **Implementar** uma estratégia de operação que avalie o risco X retorno contendo as medidas de risco (*Sharpe* e *Sortino*);
- **Validar** o modelo de previsão de tendência (RBM + KNN) com as 3 estratégias de operação propostas em um ambiente realístico as (*SmarttBot* e *Stratsphera*); e
- **Aplicar** o arcabouço metodológico o RBM + KNN em dados de bolsas norte-americanas e também em dados de criptomoedas.

Referências

- [1] G. E. Abdulaziz Almalaq. A review of deep learning methods applied on load forecasting. IEEE International Conference on Machine Learning and Applications (ICMLA), 2017.
- [2] I. Aldridge. High-frequency trading: a practical guide to algorithmic strategies and trading systems. John Wiley & Sons, 2013.
- [3] Y. Bengio. Learning Deep Architectures for AI. Foundations and Trends in Machine Learning, 2009.
- [4] K. P. V. George S. Atsalakis. Surveying stock market forecasting techniques – part ii: Soft computing methods. Expert Systems with Applications, 2009.
- [5] E. . Y. Global. Find the right people, processes and technology to manage record-to-report risks. Managing Operational Tax Risk, 2014.
- [6] A. Grimes. The Art and Science of Technical Analysis: Market Structure, Price Action, and Trading Strategies, volume 1. Editora Saraiva, 2012.
- [7] S. Haykin. Neural Networks: A Comprehensive Foundation. Prentice Hall PTR, Upper Saddle River, NJ, USA, 2nd edition, 1998.
- [8] G. E. Hinton and R. R. Salakhutdinov. Reducing the dimensionality of data with neural networks. Science, 313(5786):504–507, July 2006.
- [9] S. J. Hochreiter S. Long short-term memory. Neural computation, 9:1735–1780, 1997.
- [10] R. R. Kevin Beyer, Jonathan Goldstein. When is "nearest neighbor" meaningful? CiteSeerX, 1999.
- [11] A. V. Lemos. Comissão de Valores Mobiliários (CVM) - Programa de Treinamento de Professores. Análise Técnica (Teoria de Dow, Elliott, Gráficos e Indicadores Técnicos), 2013.

Referências

- [12] Z. Z. M Zhang. A review on multi-label learning algorithms. IEEE Transactions on Knowledge and Data Engineering, 2014.
- [13] D. S. Mansooreh Kazemilari, Abbas Mardani. An overview of renewable energy companies in stock exchange: Evidence from minimal spanning tree approach. Renewable Energy, 102:107–117, 2017.
- [14] A. F. B. e. L. L. Martín Iglesias Caride. Stock returns forecast: An examination by means of artificial neural networks. Complex Systems: Solutions and Challenges in Economics, Management and Engineering, 2017.
- [15] T. Mitchell. Machine Learning, volume 1. McGraw-Hill Science/Engineering/Math, 1997.
- [16] S. Niaki and S. Hoseinzade. Forecasting s&p 500 index using artificial neural networks and design of experiments. Journal of Industrial Engineering International, 9(1):1–9, 2013.
- [17] R. J. S. Paulo Henrique Kaupa. Rough sets: technical computer intelligence applied to financial market. International Journal of Business Innovation and Research, 13, 2017.
- [18] H. V. Roberts. Stock market patterns and financial analysis: Methodological suggestions. The Journal of Finance, 14, 1959.
- [19] S. J. Russell, P. Norvig, J. F. Canny, J. M. Malik, and D. D. Edwards. Artificial intelligence: a modern approach, volume 2. Prentice hall Englewood Cliffs, 1995.
- [20] F. B. e. J. M. Thomas Lopes. Mineração de opiniões aplicada a análise de investimentos. Sociedade Brasileira de Computação, 2008.
- [21] A. S. S. Tiago P. Oliveira, Jamil S. Barbar. Computer network traffic prediction: A comparison between traditional and deep learning neural networks. International Journal Big Data Intelligence, 3(1), 2016.
- [22] G. Varga. Índice de sharpe e outros indicadores de performance aplicados a fundos de ações brasileiros. Revista de Administração Contemporânea, 2001.
- [23] H. White. Economic prediction using neural networks: The case of ibm daily stock returns. In Neural Networks, 1988., IEEE International Conference on, pages 451–458. IEEE, 1988.

Dúvidas

