

Informe de Proyecto de Investigación

Título del proyecto	Duración	Lugar de ejecución
Natural language processing para la predicción de series de tiempo en el mercado de commodities energético con el uso de modelos en inteligencia artificial	10 Meses	Bogotá

Nombre del Investigador principal	Enlace CvLAC	Enlace ORCID	Enlace Google Académico
Miguel Antonio Alba Suárez	http://scienti.colciencias.gov.co:8081/cvlac/visualizador/generarCurriculoCv.do?cod_rh=0001325299	https://orcid.org/0000-0002-1481-2486	https://scholar.google.es/citations?view_op=new_articles&hl=es&img=Miguel+Antonio+Alba+Suarez

División	Facultad	Programa	Línea activa	Campos de acción	Grupo de investigación
División de Ciencias Administrativas y Económicas	Facultad de Negocios Internacionales	Negocios Internacionales	Estudios en Negocios Internacionales	Sociedad	Shibumi

Nombre(s) CO-Investigadores	Enlace CvLAC	Enlace ORCID	Enlace Google Académico
-----------------------------	--------------	--------------	-------------------------

Wilmer Darío Pineda Ríos	http://scienti.colciencias.gov.co:8081/cvlac/visualizador/generarCurriculoCv.do?cod_rh=0001454199	https://orcid.org/000-0001-7774-951X	https://scholar.google.es/citations?user=5KmOl5oAAAAJ&hl=es
--------------------------	---	---	---

División	Facultad	Programa	Línea activa	Campos de acción	Grupo de investigación
División de Ciencias Administrativas y Económicas	Facultad de Estadística	Estadística	Modelamiento y econometría	Sociedad	Ustadística

Resumen de la propuesta	Palabras clave
Los negocios internacionales en los mercados financieros históricamente han venido utilizando herramientas de tipo estadístico como fundamental para describir y predecir el comportamiento de los activos financieros. Ante a realidad planteada surge en el escenario de hoy en el campo del data science, el uso de la inteligencia artificial, la cual se caracteriza en la utilización de herramientas propias del Natural Language Processing (NLP) como es el caso del análisis de texto y de sentimientos del mercado, cuyo objetivo es el de identificar, si el uso de texto en el análisis de series de tiempo resulta significativo a nivel predictivo en este tipo datos secuenciales. El trabajo propuesto tienen como objetivo predecir el comportamiento del mercado de commodities energeticoetico mediante la utilización de inteligencia artificial.	Deep learning, Inteligencia artificial, Natural Language Processing, Redes neuronales artificiales

Planteamiento del problema y pregunta de investigación
Durante los distintos años del análisis de datos la forma mas adecuada para describir y ajustar datos de tipo numerico y secuencial han sido los modelos estadísticos en series de tiempo tales como los modelos en media ARMA, SARIMA, SARIMAX, TAR, etc. A su vez modelos en varianza para evaluar la volatilidad de los datos como GARCH y modelos en series de tiempo multivariados como VAR y VEC. Sin embargo, el avance progresivo en el campo de la computación en los últimos años ha brindado herramientas mas robustas para el análisis de la información, específicamente el area de inteligencia artificial con el deep learning se ha vuelto una herramienta fundamental para identificar patrones complejos en los datos y brindar mejores modelos que los anteriormente realizados con el uso de la estadística tradicional. Los

modelos característicos para el análisis de datos secuenciales hacen parte de las redes neuronales recurrentes (RNN) y son llamados Long Short Term Memory networks (LSTM) una clase de redes neuronales artificiales usadas para analizar grandes secuencias de datos. Este tipo de redes neuronales es frecuentemente usado en la ciencia de los datos para problemas relacionados al análisis de series de tiempo y ha provisto mejor capacidad predictiva que las técnicas tradicionales de predicción. La ventaja del uso de redes neuronales artificiales profundas y modelos LSTM es la gran colección de datos que pueden usarse para alimentar a los modelos y realizar predicciones, un ejemplo de esto puede ser texto e imágenes en grandes volúmenes, así como la posibilidad de hacer mixturas entre distintos modelos de deep learning como Convolutional-LSTM networks. ¿Existe una mejora significativa en la predicción en series de tiempo incluyendo texto en los modelos en inteligencia artificial?

Justificación

La era de la inteligencia artificial como un fenómeno presente en el desarrollo tecnológico ha sido de gran beneficio para muchas áreas, incluido el análisis de datos, especialmente la analítica es y será continuamente influenciada por el uso de las maquinas, esta influencia a permitido la creación de modelos más sólidos y robustos que los métodos estadísticos implementados durante décadas, el machine learning ha sido el responsable de este cambio drástico en el análisis de los datos brindando técnicas sofisticadas para describir grandes volúmenes de información y en ellos patrones complejos para encontrar mejoras en la toma de decisiones de las organizaciones. Este acercamiento a la inteligencia artificial por medio del machine learning y específicamente el área del deep learning, una clase de redes neuronales artificiales especiales para detectar patrones de gran complejidad en los datos, permitió de manera significativa en los últimos años brindar grandes avances en áreas como el Natural Language Processing, reconocimiento de imágenes y tareas complejas con enromes volúmenes de información. De otro lado el análisis en series de tiempo ha sido provisto de modelos estadísticos tales como ARIMA, SARIMAX y modelos de volatilidad GARCH, que a lo largo de los años han provisto a bancos, gobiernos y grandes organizaciones realizar el análisis de este tipo de información conformada por secuencias, en los últimos años el uso de modelos de deep learning como los Long short Term Memory networks ha resaltado por encima de la estadística en el análisis en series de tiempo.

Objetivo general

Determinar el impacto en la predicción de las redes neuronales artificiales profundas para el análisis de series de tiempo con el uso de caracteres escritos y datos numéricos en el Mercado de commodities energéticos

Objetivos específicos

1. Identificar la mejor hiper-parametrización para la red neuronal artificial propuesta en el ajuste de las series de tiempo. 2. Realizar el pre-procesamiento de textos para la inclusion en los modelos. 3. Comparar los modelos de datos numericos con la prediccion de los modelos de texto.

Marco teórico
A finales de los ochenta, pero sobre todo en los noventa surgieron un sin número mercado de derivados entre ellos opciones sobre productos financieros tales como: acciones, tasas de interés, etc; sin embargo, con el tiempo, también surgieron operaciones de derivados con activos diferentes a los financieros como los commodities (De la Vega J & Garcia M, J, 2004). La volatilidad de los precios de los commodities sobre todo de los energéticos ha ejercido un gran impacto en la economía mundial introduciendo muchas veces distorsiones en los términos de intercambio que por lo general se han traducido en recurrentes procesos de inestabilidad macroeconómica (Jacks D., O'Rourke, K & Williamson, 2009). El desempeño o las actuaciones de los mercados financieros como de commodities a nivel spot como de derivados se ha realizado mediante el uso de series de tiempo con el fin de poder predecir el futuro comportamiento de estos. Para la mayoría de los agentes del mercado, el análisis de los datos secuenciales es una herramienta necesaria en la toma de decisiones. La alineación entre los métodos estadísticos con la predicción de datos secuenciales en forma de series de tiempo ha sido visible en el estudio de los mercados financieros, con altas volatilidades y patrones difíciles de describir, analizar y modelar de manera más profunda. Durante años, el uso de los modelos ya mencionados ha descrito los fenómenos económicos sin lograr capturar los movimientos del mercado con mayor precisión o certeza. La presencia de relaciones y patrones complejos en datos secuenciales ha sido un tema estudiado desde años; actualmente, existen diversos métodos para el análisis y predicción en series de tiempo como modelos en media <i>ARIMA</i> y derivados de este como <i>ARIMAX</i>, <i>ARFIMA</i>, <i>SARIMA</i>, <i>TAR</i>. Asimismo, se ha realizado análisis de la heterocedasticidad con el uso de modelos en varianza como <i>GARCH</i> y sus variantes, así como la predicción en series de tiempo multivariado con modelos <i>VAR</i> y <i>VEC</i>. En los últimos años el desarrollo del campo de la computación ha brindado herramientas únicas para el análisis de la información en varias formas, el crecimiento de la tecnología se ha convertido en la cuarta revolución industrial, y se ha entendido como la referencia a la convergencia de las tecnologías digitales, físicas y biológicas para cambiar el mundo con la era de automatización (Perasso, 2016). Esta era, ha abierto las puertas a la innovación y el desarrollo más que cualquier otro terreno de conocimiento humano. El desarrollo de la <i>inteligencia artificial</i> (AI) como un fenómeno presente en el desarrollo tecnológico ha sido de gran beneficio en muchas áreas, incluido el análisis de datos. La edad de la analítica ha sido influenciada de manera importante con la ayuda de máquinas que hacen modelos aún más robustos que los métodos estadísticos implementados a lo largo de décadas, ramas de la informática como el aprendizaje automático (<i>Machine learning</i>) ha reforzado tareas sofisticadas en la descripción de grandes volúmenes de información y permitió mejoras en las tareas de toma de decisiones en muchas situaciones y organizaciones. En el caso del análisis de datos secuenciales como lo son las series de tiempo y lenguaje natural, la <i>inteligencia artificial</i> ha brindado herramientas únicas y sofisticadas para evaluar y modelar grandes volúmenes de información compleja. Específicamente en este campo de la ciencia como lo es la <i>inteligencia</i>

artificial, áreas como el aprendizaje profundo (*deep learning*) se hacen más populares para el tratamiento de información con patrones complejos como es el caso de las series de tiempo.

De otro lado, mientras que existen diferentes trabajos que sirven de ilustración para la predicción en series de tiempo con el uso de la clase especial de redes neuronales artificiales que proporciona el *deep learning*, hay una carencia en análisis profundo de la manera para realizar una búsqueda de la hiper-parametrización adecuada para los modelos, y adicional distintas maneras de ver la información para alimentar los modelos.

En el análisis de series de tiempo usando *deep learning*, es comúnmente usado la clase de redes neuronales artificiales llamada *Long Short Term Memory networks* (LSTM), los cuales, permiten retener grandes volúmenes de datos secuenciales de cualquier tipo, en el caso de series de tiempo, suelen resultar mejores predicciones que modelos comúnmente usados en estadística. La ventaja de esta clase de modelos es la posible predicción de caracteres escritos como palabras, análisis de texto (*text mining*) y de sentimientos (*Sentiment Analysis*).

Actualmente en la era digital el mundo financiero se mueve por los comentarios de grandes entes, gobiernos y opiniones de expertos quienes visualizan un posible futuro para los mercados, los inversionistas así mismo constantemente se encuentran viendo diferentes fuentes de información para tener más validez y criterio en sus decisiones.

Hoy en día, en el análisis de series de tiempo los modelos usados no cuentan con la inclusión de comentarios por parte de especialistas ni de situaciones o fenómenos que guarden relación con el comportamiento de los activos o commodities. El análisis de los activos suele hacerse por medio de la opinión de expertos y lo que, los modelos cuantitativos puedan describir sobre estos.

Este trabajo busca hacer una mixtura entre el análisis de los datos usando *inteligencia artificial* con los comentarios y fenómenos más relevantes en el histórico de los commodities usados, con el fin de crear un aprendizaje en los modelos lo suficientemente robusta para ser generalizados y aplicados a más problemas con relación a datos secuenciales. Se busca evaluar la capacidad predictiva de los modelos en base a la inclusión de texto en forma de opiniones de analistas, fenómenos y opiniones generales hacia los commodities del mercado energético, con el fin de identificar si se logra llegar a ganar predictibilidad en los modelos capturando patrones más complejos en los datos.

Esta aplicación del campo de la ciencia de los datos (*data science*), ciencias computacionales (*computer science*) y estudio de los mercados financieros, será de gran beneficio para los inversores e investigadores en estas áreas con una manera única y eficiente para la predicción de commodities en los mercados energéticos.

1. Inteligencia Artificial

La *inteligencia artificial* (AI) es el campo que estudia la creación y el manejo de sistemas inteligentes; estos sistemas inteligentes son entes conformados por la interacción entre un ambiente específico a través de sensores, con el fin de cambiar el estado de los agentes.

En general la *inteligencia artificial* logra la manera de hacer un mapa de las interacciones de los agentes por medio de ciertos controles. Una vez el agente inteligente basa sus decisiones en datos, el mapa general de estas decisiones es llamado como un ciclo de percepciones.

Como idea general la *inteligencia artificial* está relacionada a las máquinas y como éstas tienen una capacidad inherente de resolver problemas basadas en preguntas que deben ser solucionadas. El objetivo final de la ciencia descrita es el control proporcional en las decisiones de los agentes conforme a la mímica de las habilidades humanas y la similitud con la toma de decisiones. Es por estos objetivos de la AI que el *machine learning* fue creado y ahora está en un sin número de aplicaciones en distintas áreas del conocimiento como el campo de la medicina, robótica, juegos, finanzas, etc.

1.1 Aprendizaje Automático (machine learning)

El aprendizaje automático conocido como aprendizaje de máquinas o *machine learning* (ML) constituye una serie de algoritmos usados para dar un acercamiento más profundo a la *inteligencia artificial*. Este es ampliamente usado en el análisis de datos para realizar la tarea de automatización en algunos de los procesos, dividiendo los datos para aprender de estos con el fin de buscar patrones y así tomar una decisión en particular (SAS, 2018).

El trasfondo del *machine learning* es el uso de los computadores para lograr aprender de los datos con una clase de algoritmos particulares, con la mínima intervención humana posible. Actualmente la complejidad de las bases de datos y sistemas de información es amplia al igual que el incremento en el volumen de registros, debido a esto muchas organizaciones han

usado este tipo de técnicas provenientes de la *inteligencia artificial* con el objetivo de analizar de manera más precisa la información.

El *machine learning* busca de una manera más compleja ver y extraer patrones complejos de la información y generalizar los análisis para poder aplicar los mismos entrenamientos en nuevas piezas de información. Por esto mismo, esta técnica en el análisis de datos ha ganado popularidad en varios campos del conocimiento como el *Natural Language Processing* (NLP) o procesamiento de lenguaje natural, en este se analizan datos como textos, imágenes o videos, también campos como los sistemas transaccionales, detección de fraude crediticio y sistemas de recomendación entre otros.

Los datos usados para captar los patrones relevantes por medio de los algoritmos se les conoce como datos de entrenamiento, esta partición de los datos sirve para informar y entrenar los modelos con la suficiente información para predecir generalizar a nuevos datos.

En general existen distintos tipos de *machine learning* como *Supervise*, *Unsupervised*, *Semi-supervised* y *Reinforcement Learning*, los cuales consisten en diferentes técnicas de aprendizaje que se diferencian en la determinada forma que tienen los datos. En este trabajo se usarán metodologías partiendo del *Supervised Learning* el cual está conformado por algoritmos entrenados con el concepto de una función de aproximación. Esta función describe de manera precisa las entradas de datos basada en pares de entradas y salidas. Esto indica que los algoritmos reciben la información en forma de entradas y verifican la predictibilidad con las correspondientes salidas conocidas. Estos algoritmos buscan una función que maneje las entradas con un destinado vector objetivo o variable dependiente (*Target*) con clases o espacios continuos, como en el caso de la estadística: variables discretas, continuas y categorías o clases.

En este trabajo se explorará la clase categórica y problemas de regresión, siendo un problema de clasificación al ver las predicciones respectivas para la serie de tiempo (tendencias) y predicción numérica puntual para las series.

1.1.1 Redes neuronales artificiales (ANN)

Con el objetivo de encontrar patrones complejos en las observaciones, la serie de algoritmos inspirada en el cerebro humano que permite a los computadores aprender de los datos se le conoce como *Redes Neuronales Artificiales* (ANN- *Artificial Neural Networks*).

1.1.2 Perceptrones

Los perceptrones fueron introducidos por Warren McCulloch, Walter Pitts y Frank Rosenblatt en las décadas de los 50 y 60 (Nielsen, 2017), siendo funciones que se sirven de distintos inputs en de forma binaria dentro de un vector $\mathbf{X}$ conformado por elementos $x_1, \dots, x_n$, en respuesta a única salida binaria. Este vector de salida es calculado mediante un vector de pesos comúnmente nombrado como $\mathbf{W}$, conformado por pesos $w_1, \dots, w_n$. Donde cada uno representa la importancia establecida de las entradas a las salidas (Alba Acosta, 2018), teniendo en cuenta la definición de pesos y entradas $\sum w_i x_i \leq \alpha$, donde α es un valor límite.

Los perceptrones se agrupan en general para conformar la estructura de una red neuronal artificial, todos los valores de los parámetros anteriormente mencionados en forma de pesos, entradas y valor límite conforman la red en su totalidad y permiten de esta tomar más complejidad para encontrar patrones y tomar decisiones.

En general una red neuronal artificial tiene la siguiente forma y estructura:

Estructura Red Neuronal Artificial1

1 Imagen creada por Geetika saini, 15 de marzo de 2017. artificial neuron consisting of dendrites, axon and threshold function.

En general los perceptrones se encuentran en distintas capas, donde cada capa realiza decisiones conforme a los resultados de las anteriores; esto permite a las redes neuronales artificiales ser cada vez más robustas y difíciles de estimar conforme se aumenta el volumen de capas y de perceptrones, creando así decisiones más complejas.

REFERENCIAS

A. A., & A. P. (2015). *Mastering probabilistic Graphical Models using Python*. Birmingham B3 2PB, UK.: PACKT: publishing .

Alba Acosta, M. (2018). Predictive capacity of deep learning models in cryptocurrency market analysis.

Amjad, M. (2016). Prediction, Trading Bitcoin and Online Time Series. *NIPS 2016 Time Series Workshop*, 55. Barcelona.

Amunategui, M. (2017, 11 2). *Data Exploration & Machine Learning, Hands-on*. Retrieved from Convolutional Neural Networks And Unconventional Data - Predicting The Stock Market Using Images: <http://amunategui.github.io/unconventional-convolutional-networks/index.html>

Bontempi, G. (2013). Machine Learning Strategies for Time Series Prediction. (B. d.-C. 212, Ed.) *Machine Learning Summer School (Hammamet, 2013)*.

Brownlee, J. (2017). *Long Short-Term Memory Networks With Python: Develop Sequence Prediction Models With Deep Learning*. Machine Learning Mastery.

Cross Validated. (2015). *A list of cost functions used in neural networks, alongside applications*. Retrieved from <https://stats.stackexchange.com/questions/154879/a-list-of-cost-functions-used-in-neural-networks-alongside-applications>

De la Vega J & Garcia M, J. (2004). Análisis para negociar en el mercado de futuro. *Estrategia Financiera*, 34-41.

Elidan, G. (2010). Copula bayesian networks. (H. U. Department of Statistics, Ed.) *Advances in Neural Information Processing Systems*, 24.

Fumo, D. (2017, June 15). <https://towardsdatascience.com/types-of-machine-learning-algorithms-you-should-know-953a08248861>. Retrieved from Towards Data Science:

<https://towardsdatascience.com/types-of-machine-learning-algorithms-you-should-know-953a08248861>

G. I., B. Y., & C. A. (2016). *Deep Learning*. MIT Press.

Ghahramani, Z. (1997). Learning Dynamic Bayesian Networks. *Department of computer science, University of Toronto*.

Google. (2017). *AI adventures*. Retrieved from Youtube: <https://www.youtube.com/channel/UCJS9pqu9BzkAMNTmzNMNhvg>

H. S., & S. J. (1997, november 15). Long Short-Term Memory. *Neural Computation*, Volume 9(Issue 8).

Heaton, J. (2013, 07). Bayesian Networks for Predictive Modeling. *Forecasting & Futurism*, 6.

Jaakkola, T. (2006, Fall). Course materials for 6.867 Machine Learning. *Document Downloaded on [11 04 2018]*. Massachusetts Institute of Technology.

Jacks D., O'Rourke, K & Williamson. (2009). Commodity price volatility and world market integration since 1700.

Jimsparkle. (2017). *Understanding bitcoin market trend and feature using unsupervised Machine-Learning*. Retrieved from steemit: <https://steemit.com/bitcoin/@jimsparkle/understanding-bitcoin-market-trend-and-feature-using-unsupervised-machine-learning>

L. F.-F., J. J., & Y. S. (2017). Lecture 10 | Recurrent Neural Networks. *Recurrent Neural Networks* (pp. lecture 10-22). Stanford University.

LeCun, Y., B. L., B. Y., & H. P. (1998). *Gradient-based learning applied to document recognition*. Proc. of the IEEE.

Lewis, N. (2016). *DEEP TIME SERIES FORECASTING With PYTHON*.

Liu, A. T. (2004). A Bayesian Network Approach to Explaining Time Series with Changing Structure. *Department of Information Systems and Computing*.

M. L., & J. L. (2001). *Recurrent neural networks (design and applications)*. The Mawson Lakes, SA Australia: CRC press.

Margaritis, D. (2003, may). Learning Bayesian Network Model Structure from Data. 126. Pittsburgh, PA 15213, United States: School of Computer Science, Carnegie Mellon University.

Marr, B. (2016, December 6). *What Is The Difference Between Artificial Intelligence And Machine Learning?* Retrieved from Forbes: <https://www.forbes.com/sites/bernardmarr/2016/12/06/what-is-the-difference-between-artificial-intelligence-and-machine-learning/#7c2d4aea2742>

McNally, S. (2016, 08 22). Predicting the price of Bitcoin using Machine Learning. *MSc Reseach Project*.

Mihajlovic, & Petkovic. (2001). Dynamic Bayesian Networks: A State of the Art. *CTIT Technical Report Series, 01-34*.

N. G., M. M., & N. A. (2011). Characterization of Dynamic Bayesian Network The Dynamic Bayesian Network as temporal network. *(IJACSA) International Journal of Advanced Computer Science and Applications*., 8.

Nielsen, M. (2017). *Neural Networks and Deep Learning*.

Novick, P. (2011). *Udacity.com*. Retrieved from Intro to Artificial Intelligence: <https://classroom.udacity.com/courses/cs271>

Osterrieder, J. a. (2016, October 1). Bitcoin and Cryptocurrencies - Not for the Faint-Hearted. *Advanced Risk & Portfolio Management Paper*.

Perasso, V. (2016, 10 02). Qué es la cuarta revolución industrial (y por qué debería preocuparnos). *BBC NEWS* .

saini, G. (2017). artificial neuron consisting of dendrites,axon and threshold function. *Artificial neural network.png*. Own work.

SAS. (2018). *Machine Learning: What it is and why it matters*. Retrieved from SAS: https://www.sas.com/es_mx/insights/analytics/machine-learning.html

Scutari, M. (2015, 06). Bayesian Network Constraint-Based Structure Learning Algorithms: Parallel and Optimised Implementations in the bnlearn R Package. *Journal of Statistical Software, VV, Issue II*.

Ting Yu, N. V. (2013). *Computational Intelligent Data Analysis for Sustainable Development*. (V. Kumar, Ed.) University of Minnesota: CRC Press.

UFLDL Tutorial . (2017, 05 12). *Unsupervised Feature Learning and Deep Learning tutorial*. Retrieved from UFLDL stanford: <http://ufldl.stanford.edu/tutorial/supervised/OptimizationStochasticGradientDescent/>

Wang, H. (2016, 04 07). Towards Bayesian Deep Learning: A Survey. (Stat.ML, Ed.)

Zhou, Y. (2015, 08 08). New Techniques for Learning Parameters in Bayesian Networks. 164. Department of Computer Science.

Metodología
El desarrollo de la presente investigación va a ser de carácter cuantitativo en donde se tomaran datos secuenciales de tipo numérico y textual, en el caso de los datos numéricos se tomarán los valores que conforman las bandas de bollinger de distintos commodities en el mercado energético y textos provenientes de especialistas en este mismo mercado, así como comentarios y noticias provenientes de diferentes fuentes: Bloomberg, twitter, etc. Realización de la predicción en series de tiempo de distintos commodities usando modelos de inteligencia artificial tales como el Long Short Term Memory network (LSTM) usando datos numéricos y textos

Resultados esperados		
Tipo de producto	Detalle	Cantidad

Generación de nuevo conocimiento	Artículos de investigación	1
	Libros de investigación	
	Capítulos de investigación	
	Productos tecnológicos patentados o en proceso	
	Variedades vegetales	
Actividades de investigación, desarrollo e innovación	Productos tecnológicos certificados o validados	
	Productos empresariales	
	Regulaciones, normas, reglamentos técnicos	
	Consultorías científicas y tecnológicas	
	Innovación social	
Apropiación social del conocimiento	Participación ciudadana	
	Transferencia del conocimiento	
	Gestión del conocimiento	
	Comunicación del conocimiento	
	Circulación del conocimiento especializado	
Formación de recursos de formación	Tesis de doctorado	
	Tesis de maestría	
	Trabajos de grado	
	Proyectos de ID+i con formación	
	Apoyo a programas de formación	

Contribución del proyecto al cumplimiento con la misión institucional
• La investigación se vincula con la línea de acción número tres, que se llama proyección social en investigación pertinente ya que apuntará a que la Universidad Santo Tomás se pionera y se posicione siendo un referente internacional de excelente calidad educativa y como un agente dinamizador de la investigación en inteligencia artificial y data science. • Este proyecto se articula con el plan general de desarrollo Bogotá mediante el incremento de la producción investigativa con impacto regional, nacional e internacional ya que utiliza temas recientes y robustos de la ciencia del análisis de los datos, ciencias computacionales y financieras, contribuyendo así a el desarrollo de estas ciencias.

Líneas del PIM con las que vincula el proyecto
3. Proyección social e investigación pertinentes

Acciones del Plan General de Desarrollo 2016-2019 con el que se articula el proyecto
Incrementar la producción investigativa con impacto regional, nacional e internacional

FODEIN				
Concepto	Nombre	Escalafón	Horas mes	Total (\$)
Horas Nomina (Investigador Principal)	Miguel Antonio Alba Suarez	4	60 horas mensuales	\$ 21.727.500
Horas Nomina (Co-Investigadores)	Wilmer Dario Pineda Rios	2	30 horas mensuales	\$ 7.773.750

Concepto	Descripción	Total (\$)
		\$
Total FODEIN	\$ 29.501.250	

CONTRAPARTIDA EXTERNA				
Concepto	Nombre	Escalafón	Horas mes	Total
Horas Nomina				\$

Concepto	Descripción	Total
		\$
Total Contrapartida externa	\$	
TOTAL PROYECTO	\$ 29.501.250	

CRONOGRAMA

Actividad	Fecha Inicio	Fecha Fin
Revisión Bibliográfica	2019-02-01	2019-03-30
Consecución base de datos del mercado energético	2019-04-01	2019-04-30
Análisis teórico del natural language processing para la predicción de series de tiempo en el mercado de commodities energético con el uso de modelos en inteligencia artificial	2019-05-01	2019-06-30
Estimación utilizando inteligencia artificial en el mercado de commodities energético	2019-07-01	2019-10-31

Posibles evaluadores

• Robert Romero : estadístico, Magister en BIG DATA “Uniandes”, professor minería de datos Universidad Santo Tomas • Daniel Leonardo Cruz. Master en Inteligencia Comercial Daniel.cruz@itau.co • Alejandro correa Bahnsen, PhD machine learning university of Luxemburg. Git: <https://github.com/albahnsen>

Referencia(s)

REFERENCIAS A. A., & A. P. (2015). Mastering probabilistic Graphical Models using Python . Birmingham B3 2PB, UK.: PACKT: publishing .
Alba Acosta, M. (2018). Predictive capacity of deep learning models in cryptocurrency market analysis.

Amjad, M. (2016). Prediction, Trading Bitcoin and Online Time Series. NIPS 2016 Time Series Workshop, 55. Barcelona. Amunategui, M. (2017, 11 2). Data Exploration & Machine Learning, Hands-on. Retrieved from Convolutional Neural Networks And Unconventional Data - Predicting The Stock Market Using Images: <http://amunategui.github.io/unconventional-convolutional-networks/index.html>

Bontempi,G. (2013). Machine Learning Strategies for Time Series Prediction. (B. d.-C. 212, Ed.) Machine Learning Summer School (Hammamet, 2013).

Brownlee, J. (2017). Long Short-Term Memory Networks With Python: Develop Sequence Prediction Models With Deep Learning. Machine Learning Mastery. Cross Validated. (2015). A list of cost functions used in neural networks, alongside applications. Retrieved from <https://stats.stackexchange.com/questions/154879/a-list-of-cost-functions-used-in-neural-networks-alongside-applications>

De la Vega J & Garcia M, J. (2004). Análisis para negociar en el mercado de futuro. Estrategia Financiera, 34-41. Elidan, G. (2010). Copula bayesian networks. (H. U. Department of Statistics, Ed.) Advances in Neural Information Processing Systems, 24.

Fumo, D. (2017, June 15). <https://towardsdatascience.com/types-of-machine-learning-algorithms-you-should-know-953a08248861>. Retrieved from Towards Data Science: <https://towardsdatascience.com/types-of-machine-learning-algorithms-you-should-know-953a08248861>

G. I., B. Y., & C. A. (2016). Deep Learning. MIT Press. Ghahramani, Z. (1997). Learning Dynamic Bayesian Networks. Department of computer science, University of Toronto. Google. (2017). AI adventures. Retrieved from Youtube: <https://www.youtube.com/channel/UCJS9pqu9BzkAMNTmzNMNhvg>

H. S., & S. J. (1997, november 15). Long Short-Term Memory. Neural Computation, Volume 9(Issue 8). Heaton, J. (2013, 07). Bayesian Networks for Predictive Modeling. Forecasting & Futurism, 6. Jaakkola, T. (2006, Fall). Course materials for 6.867 Machine Learning. Document Downloaded on [11 04 2018]. Massachusetts Institute of Technology.

Jacks D., O'Rourke, K & Williamson. (2009). Commodity price volatility and world market integration since 1700.

Jimsparkle. (2017). Understanding bitcoin market trend and feature using unsupervised Machine-Learning. Retrieved from steemit: <https://steemit.com/bitcoin/@jimsparkle/understanding-bitcoin-market-trend-and-feature-using-unsupervised-machine-learning>

L. F.-F., J. J., & Y. S. (2017). Lecture 10 | Recurrent Neural Networks. Recurrent Neural Networks (pp. lecture 10-22). Stanford University. LeCun, Y., B. L., B. Y., & H. P. (1998). Gradient-based learning applied to document recognition. Proc. of the IEEE. Lewis, N. (2016). DEEP TIME SERIES FORECASTING With PYTHON.

Liu, A. T. (2004). A Bayesian Network Approach to Explaining Time Series with Changing Structure. Department of Information Systems and Computing. M. L., & J. L. (2001). Recurrent neural networks (design and applications). The Mawson Lakes, SA Australia: CRC press.

Margaritis, D. (2003, may). Learning Bayesian Network Model Structure from Data. 126. Pittsburgh, PA 15213, United States: School of Computer Science, Carnegie Mellon University.

Marr, B. (2016, December 6). What Is The Difference Between Artificial Intelligence And Machine Learning? Retrieved from Forbes: <https://www.forbes.com/sites/bernardmarr/2016/12/06/what-is-the-difference-between-artificial-intelligence-and-machine-learning/#7c2d4aea2742>

McNally, S. (2016, 08 22). Predicting the price of Bitcoin using Machine Learning. MSc Reseach Project. Mihajlovic, & Petkovic. (2001). Dynamic Bayesian Networks: A State of the Art. CTIT Technical Report Series, 01-34.

N. G., M. M., & N. A. (2011). Characterization of Dynamic Bayesian Network The Dynamic Bayesian Network as temporal network. (IJACSA) International Journal of Advanced Computer Science and Applications,, 8. Nielsen, M. (2017).

Neural Networks and Deep Learning. Novick, P. (2011). Udacity.com. Retrieved from Intro to Artificial Intelligence: <https://classroom.udacity.com/courses/cs271> Osterrieder, J. a. (2016, October 1). Bitcoin and Cryptocurrencies - Not for the Faint-Hearted. Advanced Risk & Portfolio Management Paper.

Perasso, V. (2016, 10 02). Qué es la cuarta revolución industrial (y por qué debería preocuparnos). BBC NEWS . saini, G. (2017). artificial neuron consisting of dendrites,axon and threshold function. Artificial neural network.png.

Own work. SAS. (2018). Machine Learning: What it is and why it matters. Retrieved from SAS: https://www.sas.com/es_mx/insights/analytics/machine-learning.html

Scutari, M. (2015, 06). Bayesian Network Constraint-Based Structure Learning Algorithms: Parallel and Optimised Implementations in the bnlearn R Package. Journal of Statistical Software, VV, Issue II.

Ting Yu, N. V. (2013). Computational Intelligent Data Analysis for Sustainable Development. (V. Kumar, Ed.) University of Minnesota: CRC Press. UFLDL Tutorial . (2017, 05 12). Unsupervised Feature Learning and Deep Learning tutorial. Retrieved from UFLDL stanford: <http://ufldl.stanford.edu/tutorial/supervised/OptimizationStochasticGradientDescent/>

Wang, H. (2016, 04 07). Towards Bayesian Deep Learning: A Survey. (Stat.ML, Ed.) Zhou, Y. (2015, 08 08). New Techniques for Learning Parameters in Bayesian Networks. 164. Department of Computer Science.

Documentos adjuntos

MIGUEL ALBA.pdf	ACTA COMITÉ.pdf
-----------------	-----------------