

Modelado de la Volatilidad del Índice Minero S&P BVL Utilizando Máquinas de Vectores de Soporte y un Modelo GARCH Lineal

Modeling the Volatility of the S&P BVL Mining Index Using Support Vector Machines and a Linear GARCH Model

Abraham Puente De La Vega Caceres

Universidad Andina del Cusco, Perú

adm_abraham@yahoo.com<https://orcid.org/0000-0001-8368-1136>**Cinthia Candia Candia**

Universidad Andina del Cusco, Perú

021200315a@uandina.edu.pe<https://orcid.org/0009-0000-3264-4191>**Bryans Trejo Ticona**

Universidad Andina del Cusco, Perú

020101972e@uandina.edu.pe<https://orcid.org/0009-0008-4288-4170>**Adela Leticia Aucapuri Vallenos**

Universidad Andina del Cusco, Perú

020100991f@uandina.edu.pe<https://orcid.org/0009-0000-4364-3506>**Hilary Velazco Costilla**

Universidad Andina del Cusco, Perú

017101749j@uandina.edu.pe<https://orcid.org/0009-0002-8326-3457>**Maria Luisa Palomino Huamantalla**

Universidad Andina del Cusco, Perú

020101680d@uandina.edu.pe<https://orcid.org/0009-0006-7679-9324>**Recibido:** 16/04/2024**Aceptado:** 18/06/2024**Publicado:** 30/06/2024**Auto corresponsal:**Abraham Puente De La Vega
Caceresadm_abraham@yahoo.com**Cómo citar:**Puente De La Vega Caceres, A., Aucapuri Vallenos, A. L., Candia Candia, C., Velazco Costilla, H., Trejo Ticona, B. & Palomino Huamantalla, (2024). Modelado de la Volatilidad del Índice Minero S&P BVL Utilizando Máquinas de Vectores de Soporte y un Modelo GARCH Lineal. *Integración*, 08 (1), 26-32. <https://doi.org/10.36881/ri.v8i1.882>**Fuente de financiamiento:** No financiado.**Declaración de conflictos de interés:** Los autores declaran no tener conflictos de interés.**Resumen**

Este trabajo aborda el desafío crítico de predecir la volatilidad en el mercado financiero, enfocado específicamente en el Índice Minero S&P BVL del sector minero peruano. La dificultad radica en la naturaleza compleja y dinámica de la volatilidad, que presenta desafíos significativos para los inversores y gestores de riesgos en la toma de decisiones informadas y estratégicas. Se propone evaluar la efectividad de un modelo híbrido de Regresión de Vectores de Soporte con Generalized Autoregressive Conditional Heteroskedasticity (SVR-GARCH) que incorpora un kernel lineal, frente a los enfoques convencionales GARCH. Metodológicamente, el estudio utiliza un diseño cuantitativo, recabando y procesando datos históricos diarios a través de la API de Yahoo! Finance con herramientas de programación en Python, abarcando un periodo desde el 31 de enero de 2014 hasta el 12 de febrero de 2024. Se implementa la prueba de raíz unitaria Dickey-Fuller Aumentada (ADF) para determinar la estacionariedad de la serie temporal. Los hallazgos indican que el modelo SVR-GARCH-Lineal propuesto no solo proporciona predicciones más precisas en comparación con los modelos estándar, sino que también demuestra ser robusto frente a las fluctuaciones del mercado y sensibilidades específicas del índice minero. Concluimos que el enfoque híbrido representa una mejora significativa en las herramientas de predicción y gestión de riesgos, con aplicaciones prácticas que podrían extenderse a otros índices y mercados financieros, demostrando la necesidad de incorporar técnicas de aprendizaje automático en la modelización financiera contemporánea.

Palabras claves: Volatilidad; Pronóstico; GARCH.**Abstract**

This work addresses the critical challenge of predicting volatility in the financial market, specifically focused on the S&P BVL Mining Index of the Peruvian mining sector. The difficulty lies in the complex and dynamic nature of volatility, which presents significant challenges for investors and risk managers in making informed and strategic decisions. The study proposes to evaluate the effectiveness of a hybrid model combining Support Vector Regression with Generalized Autoregressive Conditional Heteroskedasticity (SVR-GARCH) that incorporates a linear kernel, against conventional GARCH approaches. Methodologically, the study employs a quantitative design, gathering and processing daily historical data through the Yahoo! Finance API using Python programming tools, covering a period from January 31, 2014, to February 12, 2024. The Augmented Dickey-Fuller (ADF) unit root test is implemented to determine the stationarity of the time series. The findings indicate that the proposed SVR-GARCH-Lineal model not only provides more accurate predictions compared to standard models but also proves to be robust against market fluctuations and the specific sensitivities of the mining index. We conclude that the hybrid approach represents a significant improvement in prediction and risk management tools, with practical applications that could extend to other indices and financial markets, demonstrating the need to incorporate machine learning techniques in contemporary financial modeling.

Keywords: Volatility; Forecasting; GARCH.**OPEN ACCESS**
Distribuido bajo:

Introducción

El sector minero peruano constituye un pilar fundamental en la economía nacional, siendo el S&PBVL Mining Index un reflejo crítico de su comportamiento financiero. Sin embargo, la volatilidad inherente a este sector no solo encierra desafíos económicos sino también oportunidades de inversión. Este dinamismo convoca a la necesidad de herramientas de predicción efectivas y precisas para la gestión de riesgos y la toma de decisiones informadas. En este contexto, los modelos tradicionales GARCH han servido como referencia estándar, aunque no sin limitaciones en cuanto a la captura de la volatilidad en mercados financieros complejos y rápidamente cambiantes.

El sector minero peruano es crucial para la economía nacional, y el Índice Minero S&P BVL refleja su comportamiento financiero. Sin embargo, la alta volatilidad de este sector presenta desafíos significativos para la gestión de riesgos y las decisiones de inversión. Los modelos tradicionales GARCH, aunque útiles, tienen limitaciones para capturar adecuadamente la complejidad y el dinamismo de los mercados financieros. La pregunta central es ¿Puede un modelo híbrido SVR-GARCH con kernel lineal, que integra la robustez de la regresión de vectores de soporte y la dinámica de los modelos GARCH, proporcionar predicciones más precisas de la volatilidad en el S&P BVL Mining Index?

El objetivo primordial de este estudio es evaluar la efectividad del modelo híbrido SVR-GARCH con kernel lineal para pronosticar la volatilidad del S&P BVL Mining Index y comparar su desempeño con los modelos GARCH tradicionales. La hipótesis de investigación postula que el modelo híbrido SVR-GARCH con kernel lineal mejora significativamente la precisión y efectividad de las predicciones de volatilidad en comparación con los modelos GARCH tradicionales, proporcionando una base sólida para la implementación de sistemas de alerta de riesgo temprano en el sector minero peruano.

La justificación de este estudio radica en la relevancia crítica de las predicciones de volatilidad en la planificación estratégica y la gestión de riesgos. Un modelo predictivo más eficiente tiene el potencial no solo de fortalecer la estabilidad financiera del sector minero, sino también de favorecer la sostenibilidad económica nacional. Además, los hallazgos pueden ser de gran utilidad para los inversores y los reguladores del mercado, al proporcionar una comprensión más profunda de las dinámicas de riesgo en uno de los segmentos más volátiles de la economía peruana.

Antecedentes

El estudio de la volatilidad, especialmente en el sector minero peruano, crucial para el PBI y las exportaciones del país, requiere un acercamiento meticuloso y multifacético. La predicción de volatilidad, una medida de la incertidumbre del mercado, es vital para evaluar riesgos y descubrir oportunidades económicas. El trabajo de Baillie et al. (1996) con su introducción de los procesos FIGARCH, ofrece un entendimiento profundo de la persistencia en la volatilidad de las series temporales financieras, marcando un punto de inflexión en la econometría financiera.

En la vanguardia de la investigación, el estudio de Dudek et al. (2024) proporciona una perspectiva exhaustiva de los métodos estadísticos y de aprendizaje automático, destacando la precisión del SVR lineal para pronósticos de volatilidad diarios en criptomonedas, reforzando la relevancia de los enfoques híbridos en la predicción de volatilidad. Este fundamento se ve reforzado por estudios como el de Chung y Espinoza (2023) y Lux et al. (2020), que demuestran la superioridad de los modelos SVR-GARCH lineales frente a otros métodos, consolidando la idea de que la incorporación de aprendizaje automático mejora significativamente las predicciones de volatilidad frente a los modelos GARCH tradicionales.

Adicionalmente, Kuizinién et al. (2019) y Yan y Gang (2012) subrayan la robustez del SVR en la predicción de la volatilidad en diversos contextos de mercado, mientras que Yang & Li (2011) destacan la aplicación de SVR en el pronóstico de precios de opciones, proveyendo mejor precisión que los métodos paramétricos tradicionales. Karasan y Gaygısız (2020) apuntalan la mejora en la predicción de volatilidad a través de un modelo SVR-GARCH, que también incrementa la eficacia en los cálculos de VaR. Más allá de la evaluación de la volatilidad en el sector energético por Fałdziński et al. (2021), que enfatizan que el SVR con hiperparámetros bien determinados puede superar a los modelos GARCH, hay una notable ausencia de análisis específico en el sector minero peruano. La investigación presente busca llenar este vacío, aplicando un enfoque SVR-GARCH lineal y contribuyendo no solo a la academia sino a las herramientas prácticas para el manejo de riesgos en este contexto crítico.

Material y Método

La metodología SVR-GARCH-Linear, que fusiona la Regresión de Vectores de Soporte (SVR) con la

Heteroscedasticidad Condicional Autoregresiva Generalizada (GARCH) en un modelo híbrido, se aplica a datos del sector minero. Utilizando Python para extraer datos del API de Yahoo! Finance, se procede a la preparación y limpieza de los mismos. Se analizaron 2520 registros diarios del periodo del 31-01-2014 al 12-02-2024, aplicando la prueba ADF para analizar la estacionariedad de la serie. Para el modelo GARCH de orden p, q se puede expresar como:

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

Donde σ_t^2 es la varianza condicional de la serie temporal en el tiempo t, ω es el parámetro constante de la varianza, α_i y β_j son los coeficientes de los términos de autorregresión de la varianza condicional y de la volatilidad condicional pasada, respectivamente, ε_{t-i}^2 son los residuos al cuadrado en el tiempo t-i, p y q son los órdenes del modelo GARCH, que indican cuántos periodos anteriores se utilizan para calcular la varianza condicional y la volatilidad condicional, respectivamente. Por su parte, el modelo SVR Lineal se puede expresar como:

$$f(x) = \sum_{i=1}^n \alpha_i y_i K(x_i, x) + b$$

Donde $f(x)$ representa la función de predicción, x es el vector de características de entrada, n es el número de vectores de soporte, α_i son los coeficientes Lagrange, y_i son las etiquetas de los datos de entrenamiento, $K(x_i, x)$ es la función de núcleo lineal que representa el producto interno entre x_i y x, y b es el término de sesgo.

La Tabla 1 muestra resultados de la prueba de Dickey-Fuller aumentada (ADF) para el S&P BVL Mining Index y su logaritmo diferencial. El índice tiene una media de 210.75, con una desviación estándar de 53.60, indicando volatilidad. La asimetría cercana a cero sugiere una distribución simétrica, pero una curtosis negativa implica una distribución más plana que la normal. La prueba de Jarque-Bera confirma la no normalidad con un valor alto. El valor ADF de 0.70 sugiere que no podemos rechazar la hipótesis de una raíz unitaria para el índice, es decir, no estacionario. Por otro lado, la diferencia logarítmica tiene una media de cero y una desviación estándar mínima, lo que indica poca variación porcentual


y una distribución sesgada hacia la izquierda. Su alta curtosis apunta a una distribución puntiaguda y el valor ADF de 0.00 sugiere estacionariedad, lo que implica que las diferencias logarítmicas del índice son estables a lo largo del tiempo.

Tabla 1
Prueba de Dickey-Fuller Aumentada (ADF)

	Mean	Standard deviation	Skewness	Kurtosis	Jarque-Bera	ADF
S&P_BVL Mining Index	210.75	53.60	0.19	-0.84	90.35	0.70
S&P_BVL Mining Index log difference	0.00	0.02	-0.46	6.82	4966.05	0.00

La Figura 1 muestra un gráfico de tiempo de los retornos logarítmicos del S&P BVL Mining Index. Los retornos logarítmicos son una manera común de medir los retornos porcentuales continuos de un activo financiero y suelen usarse para el análisis de series temporales porque son simétricos respecto a las ganancias y pérdidas. El gráfico muestra fluctuaciones en el tiempo, con algunos picos y valles notables, lo que sugiere periodos de alta volatilidad. Esto puede indicar reacciones del mercado a eventos específicos o cambios en las condiciones del mercado.


Figura 1
Retorno logarítmico del S&P_BVL Mining Index



La Figura 2 presenta un histograma de las diferencias logarítmicas de los retornos del índice S&P BVL Mining, superpuesto con una curva normal (la línea curva). Esta visualización ayuda a evaluar la distribución de los retornos del índice y cómo se comparan con una distribución normal teórica. La forma del histograma, junto con la curva superpuesta, puede proporcionar información sobre la normalidad de los retornos. Por ejemplo, un ajuste cercano de la curva al histograma indicaría que los retornos se distribuyen aproximadamente de forma normal. Desviaciones significativas de la curva normal podrían indicar sesgo o curtosis en los retornos del índice.

Figura 2

Diferencia logarítmica en el histograma del S&P_BVL Mining Index



Resultados

En la Tabla 2, los modelos GARCH, GJR-GARCH y EGARCH exhiben un rendimiento similar con pequeñas mejoras en precisión por parte de GJR-GARCH y EGARCH, reflejadas en una reducción en RMSE a 0.1501 y MAE a 0.1483. Estos modelos también presentan un mejor manejo de la volatilidad con menores valores en HMAE y HMSE (0.1626 y 0.0272 respectivamente) comparado con GARCH (0.1671 y 0.0287).

Tabla 2

Comparación de Métricas de Error en Modelos de Pronósticos de Volatilidad


Modelo	RMSE	MAE	MSE	HMAE	HMSE
GARCH	0.1538	0.1521	0.0237	0.1671	0.0287
GJR-GARCH	0.1501	0.1483	0.0225	0.1626	0.0272
EGARCH	0.1505	0.1493	0.0227	0.1616	0.0282
SVR with Linear	0.0009	0.0008	0.0000	0.0008	0.0000

Nota. Las abreviaturas corresponden a las siguientes métricas: Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Mean Squared Error (MSE), Heteroskedasticity-Adjusted Mean Absolute Error (HMAE) y Heteroskedasticity-Adjusted Mean Squared Error (HMSE).

El modelo SVR con kernel lineal muestra resultados excepcionalmente bajos en todas las métricas, lo que podría indicar un sobreajuste: RMSE, MAE, y MSE son prácticamente nulos. Aunque impresionante, este rendimiento sugiere una necesidad de pruebas adicionales para evaluar la generalización del modelo en diferentes conjuntos de datos.

Figura 3

Predicción de volatilidad con SVR-GARCH (Lineal)



Nota. Las alertas de riesgo temprano se activan varias veces, lo que sugiere períodos potenciales de inestabilidad del mercado o eventos de volatilidad elevada en el sector minero. La presencia de estas alertas puede ser útil para los inversionistas y gestores de riesgo como señal para aplicar estrategias de mitigación de riesgos.

La Figura 3 muestra la volatilidad del S&P BVL Mining Index (índice del sector minero del mercado peruano) y su comparativa con la volatilidad predicha por un modelo SVR-GARCH lineal, destacando la correlación entre el índice de mercado y la volatilidad realizada. Las predicciones del modelo SVR siguen la tendencia de la volatilidad histórica con menor amplitud, sugiriendo una suavización en las previsiones. Significativamente, la implementación de un umbral de alerta temprana, visualizado por picos rojos cuando la volatilidad excede 0.02, identifica posibles períodos de

alto riesgo, siendo un recurso valioso para la gestión de riesgos y la toma de decisiones de inversión. El análisis del gráfico sirve para evaluar la capacidad del modelo SVR-GARCH para predecir cambios en la volatilidad y su aplicación práctica en estrategias de mitigación de riesgos financieros.

La Tabla 3 muestra que, según las pruebas Diebold-Mariano y Wilcoxon de rango con signo, hay diferencias estadísticamente significativas en la precisión de pronóstico entre la mayoría de los modelos de

predicción de volatilidad analizados; todos los valores p son prácticamente cero, excepto en las comparaciones entre GJR-GARCH y EGARCH, donde los valores p de 0.331 y 0.511, respectivamente, sugieren una precisión similar. Estos resultados resaltan la particular eficacia del modelo SVR con Linear, que muestra una diferencia significativa respecto a los modelos GARCH tradicionales.

Tabla 3
Pruebas de precisión de pronóstico: Diebold-Mariano (DM) y Wilcoxon de rango con signo (WS)

	GARCH	GJR-GARCH	EGARCH	SVR with Linear
GARCH	-	0.000	0.331	0.000
GJR-GARCH	0.008	-	0.000	0.000
EGARCH	0.000	0.511	-	0.000
SVR with Linear	0.000	0.000	0.000	-

Nota. Los valores por encima de la diagonal son valores p para la prueba DM y los valores debajo de la diagonal son valores p para la prueba WS.

Las diferencias significativas en los valores p señaladas en la Tabla 3 subrayan la superioridad del modelo SVR con Linear en comparación con los modelos GARCH tradicionales, lo que sugiere que podría ser una herramienta más eficiente y fiable para la predicción y gestión de la volatilidad en el sector minero peruano. Esta ventaja es crucial, considerando que la volatilidad de este sector puede ser impulsada por una amalgama de factores: fluctuaciones de precios internacionales de los metales, cambios regulatorios, eventos políticos, desarrollos tecnológicos y variaciones en la demanda global.

Discusiones

Nuestro estudio incursiona en el desarrollo y la evaluación de un modelo híbrido SVR-GARCH con kernel lineal para modelar y predecir la volatilidad del S&P BVL Mining Index, revelando coincidencias y discrepancias con trabajos previos. Alineándonos con Dudek et al. (2024), Chung y Espinoza (2023), Lux et al. (2020), Sun y Yu (2020), Karasan y Gaygısız (2020), Fałdziński et al. (2021), Sediono et al. (2023), Vijaya y Rajan (2022), y Yi et al. (2023), confirmamos la efectividad de combinar SVR y GARCH en la predicción de la volatilidad. Este consenso enfatiza la robustez del aprendizaje automático y los modelos estadísticos en el pronóstico financiero.

No obstante, nuestro enfoque presenta desviaciones

relevantes respecto a investigaciones como las de Dyhrberg (2016) analiza la volatilidad del Bitcoin, distanciándose de nuestro sector y de la moneda tradicional. Tung y Wong (2009) adoptan una perspectiva dinámica no lineal, mientras Santamaria-Bonfil et al. (2015) optan por algoritmos genéticos, ambos divergentes de nuestro modelo SVR-GARCH lineal. Chen et al. (2010), Bezerra y Albuquerque (2019), Xu et al. (2011) y Li et al. (2009) exploran diversas metodologías y mercados, ofreciendo un contrapunto al aplicar SVR-GARCH en nuestro contexto específico. Esta dualidad de similitudes y diferencias recalca la singularidad y el valor agregado de nuestro estudio en la literatura existente sobre la volatilidad de los mercados financieros.

Nuestros hallazgos confirman el éxito de los objetivos propuestos. Frente al objetivo de evaluar la efectividad del modelo híbrido SVR-GARCH con kernel lineal para predecir la volatilidad del S&P BVL Mining Index, los resultados muestran que el modelo SVR incurre en errores mínimos y arroja valores p significativamente bajos en comparación con los modelos GARCH, lo que señala una mayor precisión predictiva. Además, las pruebas estadísticas no indican diferencias significativas entre los modelos GJR-GARCH y EGARCH, validando así la robustez de nuestra metodología. Por último, el modelo SVR-GARCH se destaca por implementar alertas tempranas al superar un umbral de volatilidad de 0.02, demostrando su utilidad para la gestión de mitigación de riesgos.

La observación de errores mínimos y bajos valores p en el modelo SVR respalda la hipótesis de que el modelo híbrido SVR-GARCH con kernel lineal mejora la precisión predictiva para la volatilidad del S&P BVL Mining Index. Este resultado concreta nuestra Hipótesis 1, que postula una superioridad en precisión del modelo híbrido frente a los GARCH tradicionales. Asimismo, la ausencia de diferencias significativas entre los modelos GJR-GARCH y EGARCH refuerza la Hipótesis 2, que anticipa un rendimiento comparable en la predicción de volatilidad. Además, la implementación de alertas tempranas en el SVR-GARCH, que se activan al detectar un incremento en la volatilidad, corrobora la utilidad práctica del modelo en la gestión de riesgos, apoyando la efectividad de nuestras estrategias de prevención de riesgos.

Se efectuó un análisis crítico de los resultados, identificando ciertas restricciones. Una limitación relevante es el potencial sobreajuste del modelo SVR con kernel lineal, lo que podría restringir la aplicabilidad

de nuestras conclusiones a otros conjuntos de datos o condiciones de mercado. Además, persiste la necesidad de validación adicional en diversos períodos y contextos para garantizar la robustez del modelo. No obstante, la innovación en el modelado y la mejora en la precisión predictiva, junto con la aplicación práctica en la gestión de riesgos, sostienen la validez de nuestro modelo y proporcionan una base sólida para nuestras conclusiones.

Conclusiones

El presente estudio aporta significativamente al ámbito de la econometría financiera al evidenciar la mejora en la precisión de la predicción de volatilidad que proporciona el modelo híbrido SVR-GARCH con kernel lineal, demostrando así la relevancia de los enfoques híbridos en el análisis de mercados. Además, refuerza la teoría económica sobre la modelación de mercados y destaca su impacto práctico, particularmente en la

gestión de riesgos mineros, donde la predicción efectiva de la volatilidad es crucial dada la influencia significativa de este sector en el PBI y las exportaciones del país. No obstante, las limitaciones del estudio, como el potencial sobreajuste y la necesidad de validación en diversos escenarios, deben ser consideradas para garantizar la aplicabilidad del modelo. Además, en el contexto de conflictos sociales que han mermado el crecimiento del sector minero, este modelo adquiere relevancia práctica al proporcionar herramientas para anticipar y gestionar los riesgos asociados con la volatilidad del mercado, lo cual puede contribuir a una mejor toma de decisiones y mediación entre las comunidades y las empresas mineras. Se sugiere, por tanto, que investigaciones futuras aborden estas limitaciones y evalúen la aplicabilidad del modelo SVR-GARCH en otros sectores económicos y en condiciones de mercado fluctuantes, mejorando así la intermediación y la gestión de conflictos para un crecimiento sostenido del sector minero.

Referencias Bibliográficas

- Baillie, R. T., Bollerslev, T., & Mikkelsen, H. O. (1996). Fractionally integrated generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 74(1), 3–30. [https://doi.org/10.1016/S0304-4076\(95\)01749-6](https://doi.org/10.1016/S0304-4076(95)01749-6)
- Bezerra, P. C. S., & Albuquerque, P. H. M. (2019). Volatility forecasting: The support vector regression can beat the random walk. *Economic Computation and Economic Cybernetics Studies and Research*, 53(4), 115–126. <https://doi.org/10.24818/18423264/53.4.19.07>
- Chen, S., Härdle, W. K., & Jeong, K. (2010). Forecasting volatility with support vector machine-based GARCH model. *Journal of Forecasting*, 29(4), 406–433. <https://doi.org/10.1002/for.1134>
- Chung, V., & Espinoza, J. (2023). Latin american market asset volatility analysis: a comparison of garch model, artificial neural networks and support vector regression. *Applied Computer Science*, 19(3). <https://doi.org/10.35784/acs-2023-21>
- Dudek, G., Fiszeder, P., Kobus, P., & Orzeszko, W. (2024). Forecasting cryptocurrencies volatility using statistical and machine learning methods: A comparative study. *Applied Soft Computing*, 151. <https://doi.org/10.1016/j.asoc.2023.111132>
- Dyrhberg, A. H. (2016). Bitcoin, gold and the dollar - A GARCH volatility analysis. *Finance Research Letters*, 16, 85–92. <https://doi.org/10.1016/j.frl.2015.10.008>
- Faldziński, M., Fiszeder, P., & Orzeszko, W. (2021). Forecasting volatility of energy commodities: Comparison of garch models with support vector regression. *Energies*, 14(1). <https://doi.org/10.3390/en14010006>
- Karasan, A., & Gaygısız, E. (2020). Volatility Prediction and Risk Management: An SVR-GARCH Approach. *Journal of Financial Data Science*, 2(4), 85–104. <https://doi.org/10.3905/jfds.2020.1.046>
- Kuiziniene, D., Varoneckienė, A., & Krilavičius, T. (2019). Cryptocurrencies short-term forecast: Application of ARIMA, GARCH and SVR models. *CEUR Workshop Proceedings*, 2470, 70–73.
- Li, N., Liang, X., Li, X., Wang, C., & Wu, D. D. (2009). Network environment and financial risk using machine learning and sentiment analysis. *Human and Ecological Risk Assessment*, 15(2), 227–252. <https://doi.org/10.1080/10807030902761056>
- Lux, M., Härdle, W. K., & Lessmann, S. (2020). Data driven value-at-risk forecasting using a SVR-GARCH-KDE hybrid. *Computational Statistics*, 35(3), 947–981. <https://doi.org/10.1007/s00180-019-00934-7>
- Santamaría-Bonfil, G., Frausto-Solis, J., & Vázquez-Rodarte, I. (2015). Volatility Forecasting Using Support Vector Regression and a Hybrid Genetic Algorithm. *Computational Economics*, 45(1), 111–133. <https://doi.org/10.1007/s10614-013-9411-x>

- Sediono, Andreas, C., Mardianto, M. F. F., Ana, E., & Suliyanto. (2023). Forecasting the Volume of Electronic Money Transactions Using ARIMAX-GARCH Model and Support Vector Regression. *AIP Conference Proceedings*, 2975(1). <https://doi.org/10.1063/5.0187234>
- Sun, H., & Yu, B. (2020). Forecasting Financial Returns Volatility: A GARCH-SVR Model. *Computational Economics*, 55(2), 451–471. <https://doi.org/10.1007/s10614-019-09896-w>
- Tung, H. K. K., & Wong, M. C. S. (2009). Financial risk forecasting with nonlinear dynamics and support vector regression. *Journal of the Operational Research Society*, 60(5), 685–695. <https://doi.org/10.1057/palgrave.jors.2602594>
- Vijaya, C. K. R. M., & Rajan, P. (2022). A Hybrid Machine Learning Approach for Price Forecasting in Electricity Market with Smart Bidding Strategies and Wind Energy Influence. *International Review on Modelling and Simulations*, 15(6), 414–424. <https://doi.org/10.15866/iremos.v15i6.22653>
- Xu, J., Liu, J., & Zhao, H. (2011). Financial forecasting: Comparative performance of volatility models in chinese stock markets. *Proceedings - 4th International Joint Conference on Computational Sciences and Optimization, CSO 2011*, 1220–1225. <https://doi.org/10.1109/CSO.2011.136>
- Yan, G. L., & Gang, L. Y. (2012). Prediction on fund volatility based on SVRGM-GARCH model. *In Advanced Materials Research (Vols. 403–408)*. <https://doi.org/10.4028/www.scientific.net/AMR.403-408.3763>
- Yang, J.-H., & Li, L. (2011). Option price forecasting model based on SVR. *Xitong Gongcheng Lilun Yu Shijian/System Engineering Theory and Practice*, 31(5), 848–854.
- Yi, X., Wen, X., & Yin, X. (2023). Time series prediction and application based on multi-kernel support vector regression. *Proceedings of SPIE - The International Society for Optical Engineering*, 12721. <https://doi.org/10.1117/12.2683400>