

Solving a quadratic programming problem using support vector regression algorithm

Resolver un problema de programación cuadrática utilizando un algoritmo de regresión vectorial de soporte

Fernández Cariola¹, Cecilia Beate², Rosaura Meza³

¹Department of Mathematics, Universidad Nacional de San Agustín de Arequipa, Peru

²Department of Mathematics, Universidad Científica del Sur, Peru

³Department of Mathematics, Instituto del Mar del Peru, Peru

Abstracto

En el aprendizaje automático, generalmente esperamos que los datos de muestra obtenidos sean lo más precisos posible para construir un modelo exacto. Por ejemplo, el modelo del sistema a menudo guía aplicaciones reales en procesos industriales complejos. Y el éxito de las aplicaciones basadas en modelos generalmente depende de cómo los modelos reproducen exactamente el comportamiento del proceso industrial real que representan.

Palabras clave: problema de programación cuadrática, algoritmo de regresión vectorial, aplicación basada en modelos, incertidumbres

Abstract

In machine learning, we usually hope that the obtained sample data are as precise as possible in order to construct an exact model. For example, the system model often guides real applications in complex industrial process. And the success of the model-based applications generally depends on how exactly models reproduce the behavior of the real industrial process that they represent.

Keywords: Quadratic programming problem, vector regression algorithm, model-based application, uncertainties

1.Introducción

En el aprendizaje automático, solemos esperar que los datos obtenidos Los datos de la muestra son lo más precisos posible para construir un modelo exacto[1]. Por ejemplo, el sistema modelo a menudo guía aplicaciones reales en complejos proceso industrial. Y el éxito del modelo aplicaciones generalmente depende de cómo exactamente los modelos reproducir el comportamiento del proceso industrial real que ellos representan[2].

Sin embargo, los datos de la muestra suelen ser imprecisos y en algún caso puede faltar, debido a las diversas limitaciones. Por ejemplo, incluso bajo el mismo condiciones experimentales con las mismas herramientas de medición, los datos obtenidos suelen diferir de unos a otros porque las herramientas de medición nunca son perfectamente precisas y cambios de las condiciones ambientales en la industria medidas[3]. Además, la discretización se utiliza para describir cualitativamente los datos de la muestra para acelerar mejorar el proceso de aprendizaje cuando la formación existente a gran escala conjunto de datos^{3, 4}, es decir, los datos a menudo tienen la característica de incertidumbre en la vida real. Generalmente, el intervalo es un herramienta para describir los datos con incertidumbre[4].

Actualmente, se ha trabajado poco para estudiar admite máquinas vectoriales (SVM) con intervalo información. Clasificación de vectores de soporte basada en intervalos Los problemas se discuten en la literatura, mientras que Chuang y Hwang prestaron atención a la regresión problemas con la salida de intervalo[5]. Sin embargo, los métodos de Chuang y Hwang no se basaron completamente en intervalo porque los datos de entrada que utilizaron todavía eran nítidos, no intervalo, es decir, sus métodos se basaron en crispinput intervalo de salida (CIIO) en su investigación[6].

2.Revisión de literature

En este artículo, el intervalo-entrada-intervalo-salida (IIIO) Los problemas basados en la regresión de vectores de soporte (SVR) son discutido. Además, damos dos definiciones de precisión de la predicción para evaluar las diferencias entre salidas previstas y salidas reales[7].

El resto del artículo está organizado de la siguiente manera. En, discutimos el enfoque descompuesto para tratar con problemas IIIO basados en la técnica SVR. Primero nosotros dar la idea básica, y luego los resultados de la simulación son demostrado. Finalmente, dos definiciones de predicción precisión para evaluar las diferencias entre las predicciones Se presentan productos y productos reales. Siguiendo esto la sección 3 estudia la programación cuadrática (QP) basada Método SVR para resolver problemas IIIO. Sección 4 concluye el artículo con un breve resumen[8].

Ahora demostramos los resultados del método a través de dos experimentos. Para obtener alguna muestra datos, primero generamos 150 puntos a partir de la función Si, cuya expresión es como Carolina del Norte $f(x) = \text{Sinc}(x) = \frac{\sin(x)}{x}$, y 2- función dimensional de Gabor16, cuya expresión es como , respectivamente; luego cree 150 pares de intervalo seleccionando dos puntos al azar entre ellos cada vez[9]. Finalmente, al azar seleccione uno de los 120 pares de intervalos como entrenamiento datos, el resto como datos de prueba. En los experimentos, LIBSVM $f(x) = 0.5\pi * \exp(-2x^2) \cos(2\pi x^2)$ se utiliza y Guassian RBF se selecciona como el núcleo de SVR. Además, validación cruzada de 10 veces El método se utiliza para obtener los parámetros del kernel. funciones.

La función y los datos de muestra generados a partir de ella se muestran, mientras que muestra resultados de predicción entre intervalos predichos y reales intervalo. En la figura 2, la línea de puntos denota el real intervalos y la línea real denota el predicho intervalos. Los símbolos de "más" y "estrella" denotan la centros de intervalos reales e intervalos predichos, respectivamente[10].

3.Discusión

La función de Gabor bidimensional y generada Los datos de muestra de él se muestran, mientras que muestra los resultados de la predicción entre los intervalos predichos. e intervalo real. En la figura 4, la línea de puntos denota el intervalos reales y la línea real denota la predicción intervalos. Los símbolos de "más" y "estrella" denotan la centros de intervalos reales e intervalos predichos, respectivamente[11].

Para evaluar las diferencias entre las predicciones intervalos e intervalos reales, definimos dos expresiones de precisión de predicción de la siguiente manera.

Suponga la salida de intervalo real y el intervalo predicho salida correspondiente al mismo intervalo entrada I y X son denotados por y_0 y Y y y_0 y Y . El área del rectángulo por intervalo y $Y\% y_0$ y X y i se denota por el área de rectángulo construido por el intervalo I y Y real I a X y y_0 se denota por $Y\% \text{ pred } i$ A, y el área superpuesta entre los anteriores los rectángulos se denotan por vuelta I a [12]. Según la expresión, las tasas de precisión en los dos experimentos son los siguientes: i) para la muestra datos generados a partir de la función Sinc, $\text{Accu}_1 = 0.81221$ y $\text{Accu}_2 = 0.96736$; ii) para los datos de muestra generado a partir de la función de Gabor 2-diminutiva, $\text{Accu}_1 = 0.88778$, $\text{Accu}_2 = 0.97547$. De los resultados de los experimentos, la tasa de precisión en la segunda forma es más alto que el primero, y este hecho es fácil de entiendo porque eso, cuando el rectángulo superpuesto construido por la salida de intervalo predicha es grande en el gran entrada de intervalo y pequeña en la entrada de intervalo pequeño, la grandes rectángulos superpuestos "debilitarán" las influencias de los pequeños según la segunda formulación de precisión de la predicción[13].

Como sabemos, el algoritmo estándar de SVR puede ser realizado mediante la resolución de una programación cuadrática (QP) problema, y luego utiliza el truco del kernel. Entonces ahora un se encuentra el problema, es decir, ¿podemos construir un intervalo Modelo SVR resolviendo un problema QP como SVR estándar? Supongamos que tenemos los conjuntos de datos de intervalos como expresión expresión, y la expresión no lineal Modelo de regression[14].

4.Conclusión

De manera similar para construir la pérdida cuadrática estándar algoritmo de SVR basado en funciones, el intervalo basado en QP Modelo SVR[15].

Sin embargo, la formulación es el modelo primario de intervalo RVS. Cómo resolver eficientemente su doble problema y haga un buen uso del truco del kernel, o realice directamente en el problema primario18 es todavía un tema de investigación adicional[16].

Hemos presentado los enfoques para abordar el problema con intervalo-entrada intervalo-salida usando vector de soporte algoritmo de regresión en este artículo. También tenemos propuso dos formas de evaluar la precisión de la

predicción, es decir, las diferencias entre los valores predichos y los valores reales valores. En trabajos futuros, pretendemos resolver la propuesta Modelo SVR de intervalo basado en QP y emplearlos para aplicaciones industriales.

Referencias

- [1] Cheng, K., Lu, Z. “Adaptive sparse polynomial chaos expansions for global sensitivity analysis based on support vector regression”, (2018) *Computers and Structures*, 194, pp. 86-96.
- [2] Rastogi (nee Khemchandani), R., Anand, P., Chandra, S. “-norm Twin Support Vector Machine-based Regression”, (2017) *Optimization*, 66 (11), pp. 1895-1911.
- [3] Shim, J., Hwang, C., Seok, K. “Support vector quantile regression with varying coefficients”, (2016) *Computational Statistics*, 31 (3), pp. 1015-1030.
- [4] Yuan, F.-C., Lee, C.-H. “Using least square support vector regression with genetic algorithm to forecast beta systematic risk”, (2015) *Journal of Computational Science*, 11, pp. 26-33.
- [5] Chen, S., Jeong, K., Härdle, W.K. “Recurrent support vector regression for a non-linear ARMA model with applications to forecasting financial returns”, (2015) *Computational Statistics*, 30 (3), pp. 821-843.
- [6] Li, D., Wilson, P.A., Jiang, Z. “An improved support vector regression and its modelling of manoeuvring performance in multidisciplinary ship design optimization”, (2015) *International Journal of Modelling and Simulation*, 35 (3-4), pp. 122-128.
- [7] More, N.S., Ingle, R.B. “Energy-Aware vm migration using dragonfly-crow optimization and support vector regression model in cloud”, (2018) *International Journal of Modeling, Simulation, and Scientific Computing*, 9 (6), art. no. 1850050.
- [8] Zhou, Q., Shao, X., Jiang, P., Zhou, H., Shu, L. “An adaptive global variable fidelity metamodeling strategy using a support vector regression based scaling function”, (2015) *Simulation Modelling Practice and Theory*, 59, pp. 18-35.
- [9] Hu, Z., Kang, H., Zheng, M. “Stream data load prediction for resource scaling using online support vector regression”, (2019) *Algorithms*, 12 (2), art. no. 37.
- [10] Yaohao, P., Albuquerque, P.H.M. “Non-Linear Interactions and Exchange Rate Prediction: Empirical Evidence Using Support Vector Regression”, (2019) *Applied Mathematical Finance*, 26 (1), pp. 69-100.
- [11] Moqaddasi Amiri, M., Tapak, L., Faradmal, J. “A mixed-effects least square support vector regression model for three-level count data”, (2019) *Journal of Statistical Computation and Simulation*, 89 (15), pp. 2801-2812.
- [12] Rustam, Z., Kintandani, P. “Application of Support Vector Regression in Indonesian Stock Price Prediction with Feature Selection Using Particle Swarm Optimisation”, (2019) *Modelling and Simulation in Engineering*, 2019, art. no. 8962717.
- [13] Li, Z., Song, G., Xu, Y. “A fixed-point proximity approach to solving the support vector regression with the group lasso regularization”, (2018) *International Journal of Numerical Analysis and Modeling*, 15 (1), pp. 154-169.
- [14] Gao, H., Li, C. “An object-oriented classification for hyperspectral remote sensing images based on improved genetic algorithm and support vector regression”, (2015) *Journal of Computational and Theoretical Nanoscience*, 12 (11), pp. 4624-4631.
- [15] Fischer, A., Langensiepen, G., Luig, K., Strasdat, N., Thies, T. “Efficient optimization of hyper-parameters for least squares support vector regression”, (2015) *Optimization Methods and Software*, 30 (6), pp. 1095-1108.
- [16] Peng, T., Tang, Z. “A small scale forecasting algorithm for network traffic based on Relevant Local Least Squares Support Vector Machine regression model”, (2015) *Applied Mathematics and Information Sciences*, 9 (2), pp. 653-659.