

Interpolación Espacial Mediante Aprendizaje de Máquinas en Viñedos de la Provincia de Mendoza, Argentina.

F. Bromberg, D. S. Pérez

Laboratorio de Inteligencia Artificial DHARMa
Departamento de Sistemas de la Información, UTN Regional Mendoza
Rodríguez 273, CP 5500, Mendoza, Argentina.
{fbromberg,sebastian.perez}@frm.utn.edu.ar
<http://dharma.frm.utn.edu.ar>

Resumen El presente trabajo se enmarca en el problema de interpolación espacial de variables vitícolas por medio de *Support Vector Machines (SVM)* y *Local SVM (LSVM)*, a partir de mediciones geo-espaciales en viñedos de distintas bodegas de la provincia de Mendoza. Los resultados de estas técnicas son comparados con los dos métodos de interpolación de uso más extendido empleadas en Viticultura de Precisión para el modelado de datos agrícolas: *Inverse Distance Weighting (IDW)* y *Kriging*. Los resultados obtenidos en este trabajo muestran una mejora en la calidad de las interpolaciones, condicionada en la cantidad de datos disponibles, donde *LSVM* y *SVM* en general obtienen resultados de mayor calidad.

Palabras claves: *Machine Learning, Precision Viticulture, Support Vector Machines, Local Support Vector Machines, Spatial Interpolation.*

1. Introducción

En la actualidad, y con técnicas de modelización tradicionales, la toma de decisiones agrarias es inherentemente riesgosa, sujeta a importantes incertezas sobre sus consecuencias. Sin embargo, en las últimas dos décadas, gracias a la disponibilidad de las nuevas tecnologías geo-espaciales, se ha comenzado a administrar las explotaciones agrarias de forma más precisa, recolectando y almacenando información espacial de diversas variables, como ser cultivo, suelo, altitud, clima y otros. Este conjunto de tecnologías que mejoran la gestión de la producción agrícola reciben el nombre de *Agricultura de Precisión (AP)* ([Bramley, 2009], [Taylor and Whelan, 2005]). Las mismas permiten dilucidar que la productividad de los cultivos en un área puede variar considerablemente, incluso en distancias muy cortas, aumentando la probabilidad de que las *estrategias de administración* sean apropiadas y se apliquen en el lugar correcto en el momento adecuado. El resultado esperado de estas técnicas es la reducción en las incertezas inherentes a los fenómenos que afectan la producción agrícola.

Cuando la AP se aplica específicamente a la administración de viñedos toma el nombre de *Viticultura de Precisión (VP)* ([Bramley and Lamb, 2003], [Arnó Satorra *et al.*, 2009]). La VP permite a los viticultores y enólogos adquirir y gestionar información geo-referenciada detallada sobre las variables involucradas en el cultivo de la vid, conocer y comprender por qué la cosecha varía dentro de una misma parcela, cuáles son las causas de dicha variación y cómo se correlaciona la cosecha con su calidad. De esta manera la VP afirma los procesos de toma de decisiones agronómicos, económicos y ambientales, mejorando el rendimiento y la calidad del cultivo y aumentando la rentabilidad del producto. Algunos aportes de la VP que se pueden citar son: predicción de calidad de la uva y rendimiento del cultivo para una cosecha; detección de zonas de productividad alta, media y baja; detección y predicción de enfermedades; aplicación precisa de fertilizantes y pesticidas; distribución precisa del riego; maximización de la eficiencia de los insumos; minimización del impacto ambiental negativo, y más ([Arnó Satorra *et al.*, 2009]).

En este contexto, la utilización de técnicas de interpolación está motivada por el elevado costo que representa la medición de algunas variables agrícolas. Muchas veces las decisiones del agricultor dependen directamente de esta costosa información. La solución a éste problema consiste en tomar una muestra aleatoria pequeña de la población total y utilizar técnicas de interpolación espacial para inferir los valores restantes. De esta manera se pueden obtener modelos de predicción de productividad y calidad más robustos ante la falta de datos.

Desafortunadamente, la AP se ha visto limitada al intentar modelizar e interpolar la información medida utilizando exclusivamente técnicas estadísticas tradicionales. La información provista por la AP no solo presenta variaciones espaciales de pequeña escala y con gran correlación espacial, sino que además presenta correlaciones fuertes, muchas veces no lineales, entre valores de las distintas variables medidas. Es por eso que, entre el conjunto de tecnologías que conforman la AP se pueden hallar técnicas de *Machine Learning (ML)*, como ser *Neural Networks*, *Kernel Methods*, *Mixture Models*, *Bayesian Learning*, *Genetic Algorithms* ([Mitchell, 1997], [Bishop, 2009]) para la generación asistida o automatizada de modelos agrícolas.

Este trabajo está orientado al estudio, implementación y análisis de dos técnicas propias de ML, *SVM* ([Campbell, 2001], [Bishop, 2009]) originalmente propuestas para interpolación espacial por [Kanevski and Camu, 2000] (ver también el sitio <http://www.geokernels.com> mantenido por el autor), y *LSVM* ([Bottou and Vapnik, 1992], [Gilardi and Bengio, 2000]), aplicadas al problema de interpolación de variables vitícolas a partir de mediciones geo-espaciales. La calidad de estos algoritmos es comparada con dos técnicas de interpolación estadística muy empleadas por la AP en el modelado de datos agrícolas: *Inverse-distance weighting (IDW)* ([Shepard, 1968]) y *Kriging* ([Cressie, 1990], [Cressie, 1992]).

2. Elementos del Trabajo y Metodología

Los datos necesarios para llevar a cabo la experimentación propuesta han sido suministrados por la empresa *Xoomcode S.A.*, una empresa local especializada en servicios de geolocalización. Esta información se encuentra distribuida en distintos datasets compuestos de mediciones tomadas en viñedos de importantes bodegas mendocinas (*Agrícola Altamira, Cobos, Foster, Las Divas, Serenade, Teresa Mosso y Vistalba*), sobre un total de 13 variables que intervienen en procesos vitícolas de distintas variedades de uva, como ser *Malbec, Cabernet Sauvignon y Chardonnay*. En la Tabla 1 se puede consultar una breve descripción de las variables abordadas en este trabajo.

Tabla 1. Descripción de las variables vitícolas abordadas.

Variable	Descripción
BCW	Peso de Racimo
BUDS	Yemas no Brotadas
BWH	Peso de Bayas
BXB	Cantidad de Bayas
DDT	Diámetro de Tronco
LEN	Longitud de Entrenudo
MAD	Longitud de Primer Alambre Descubierta
PCLA	Plantas Por Claro
PDP	Peso de Poda
RDP	Riqueza de Poda
SHC	Brotos Totales
SHOOT	Brotos de Yemas Francas
SXL	Longitud de Brote

Se aprendió un modelo de interpolación para cada variable a estimar, acompañando cada muestras de la variable por sus coordenadas (X, Y) correspondientes al punto en el que han sido tomadas. Cada uno de los datasets ha sido dividido en dos conjuntos disjuntos, *TRAINSET* y *TESTSET*. El primero, con el 75% de los ejemplos del dataset original, esta reservado para propósitos de entrenamiento de los algoritmos, mientras que el segundo, con el 25% de los ejemplos restante, se utiliza para evaluar la calidad de los mismos.

Las principales técnicas de interpolación utilizadas en AP, i.e. *IDW* y *Kriging*, tienen limitaciones importantes que las técnicas de aprendizaje no poseen. Es posible demostrar teóricamente que *Kriging* es mejor interpolador que *IDW* ([Cressie, 1992]), pero es automatizable solo parcialmente ya que requiere ajustar una función de interacción espacial llamada *variograma* ([Matheron, 1963], [Cressie, 1990]), proceso que en la práctica requiere de intervención humana. Otro problema con *Kriging* es que asume una media espacial nula. Esto puede resolverse aplicando *Kriging* al resultado de restarle a los valores medidos la media espacial. Esta solución requiere sin embargo conocer esta media espacial, lo que a su vez requiere de un modelo del proceso subyacente. En este trabajo,

los modelos de *variograma* generados para Kriging han sido del tipo *Exponential*, *Spherical*, *Gaussian* y *Matern* ([Cressie, 1992]), reportando en los experimentos solo aquel resultado que generó el menor error absoluto en la interpolación bajo la etiqueta *KRG**.

En contraste, las técnicas de aprendizaje permiten la generación automatizada de modelos de interpolación a partir de los datos. El objetivo del trabajo es la aplicación de *SVM* y *LSVM* al problema de interpolación espacial, además de la implementación de experimentos sistemáticos para comparar la calidad de éstas frente a *IDW* y *Kriging*. *SVM* se hizo popular para resolver problemas de clasificación y luego se extendió a problemas de regresión. Una revisión completa del tema se puede encontrar en [Bishop, 2009] y [Campbell, 2001], y aplicaciones de interpolación espacial [Kanevski and Canu, 2000]. Más tarde se propuso la técnica *LSVM* ([Bottou and Vapnik, 1992]) como una mejora para problemas en los que los datos no se encuentran distribuidos uniformemente. Este método puede mejorar significativamente los resultados de interpolación mediante la construcción de múltiples modelos locales en lugar de un único modelo global ([Gilardi and Bengio, 2000]). Este algoritmo construye un modelo SVM por cada punto a ser estimado, tomando en cuenta solo un subconjunto de puntos del *TRAINSET*. Este subconjunto es elegido sobre la base de la *distancia euclídea* entre el punto a ser estimado y los puntos de entrenamiento, aprendiendo el modelo SVM solamente con aquellos que puntos del *TRAINSET* que se encuentran dentro de cierto radio definido por el usuario con centro en el punto a estimar. En la Figura 1 se puede observar el comportamiento general del algoritmo, donde p_1 es el punto a estimar y $\{v_1, v_2, v_3, v_4\} \in \text{TRAINSET}$ son sus *puntos vecinos* cuya distancia euclídea resulta menor al radio r , los cuales se usan para entrenar el modelo SVM local para p_1 .

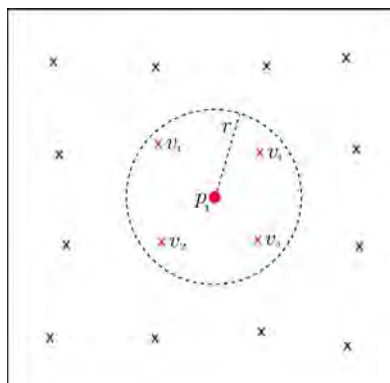


Figura 1. Esquema general para el algoritmo LSVM, siendo p_1 el punto a estimar, r el radio y v_1, v_2, v_3, v_4 sus vecinos.

En este trabajo, tanto *SVM* como *LSVM*, se han utilizado como regresores de tipo ν -regression ([Schölkopf *et al.*, 2000]), empleando como kernel una *radial basis functions* ([Campbell, 2001], [Bishop, 2009]). El conjunto de parámetros que definen *SVM* y *LSVM* son variados en tipo y número y la comprensión total de los mismo requiere de un profundo entendimiento teórico sobre los algoritmos y el problema, por lo que invitamos al lector a seguir la referencias para conocer mayores detalles. Estos parámetros han sido obtenidos a través de la técnica *5-fold cross-validation* independientemente para el entrenamiento y la evaluación, eligiendo la combinación de valores de los parámetros que lograron el menor error de validación. En la Tabla 2 se pueden consultar los parámetros utilizados, una breve descripción de los mismo ([Campbell, 2001]), y el rango de valores discretos considerados para cada uno en el cross-validation.

Tabla 2. Parámetros para los algoritmos SVM y LSVM, ambos usados como regresores de tipo ν -regression con un kernel *radial basis functions*. La segunda columna indica el rango de valores considerado en cross-validation.

Parámetro	Valores	Descripción
γ	0.0005, 0.001, 0.01, 0.1, 1, 10, 100, 1000	Representa el <i>margen</i> , i.e., la distancia perpendicular entre el hiperplano de separación y un hiperplano a través de los puntos más cercanos (que son los <i>support vectors</i>).
C	1.0	Parámetro de penalización por violar una restricción. Es una constante en el término de regularización en la formulación de Lagrange.
ν	0.01, 0.03, 0.05, 0.1, 0.3, 0.5, 0.75, 0.9	Constante usada para controlar el número de errores permitidos.
r	0.1, 0.15, 0.2, 0.25, 0.3, 0.4, 0.5, 0.75, 1	Radio de inclusión de vecinos en LSVM. Representa una proporción que se multiplica por la distancia mayor entre dos puntos del dataset.

Como medida de calidad para la comparación de los algoritmos se presenta la Media del Error Absoluto (MAE), la Desviación Estándar del Error Absoluto (SDAE) y la Raíz del Error Cuadrático Medio (RMSE) de predicción sobre la variable a predecir, calculados como

$$MAE_X = \frac{\sum_{t=1}^N |ValX_t - PredX_t|}{N}, \quad (1)$$

$$SDAE_X = \sqrt{\frac{\sum_{t=1}^N (|PredX_t| - MAE_X)^2}{N}}, \quad (2)$$

$$RMSE_X = \sqrt{\frac{\sum_{t=1}^N (ValX_t - PredX_t)^2}{N}}, \quad (3)$$

donde N es el número de ejemplos del conjunto de testeo, $PredX_t$ es el valor estimado de la variable X y $ValX_t$ es el valor real de la variable X para el ejemplo

t. En este punto cabe destacar que la SDAE es una medida de la variabilidad espacial del error, lo que supone que para valores de SDAE elevados el error cometido en algunos puntos a estimar es muy grande. Atendiendo al objetivo de los mapas de interpolación en Agricultura de Precisión, una gran variabilidad en los errores de estimación implica mayor incertidumbre en la toma de decisiones basadas en esta información.

Por lo tanto, en la experimentación se presentan los resultados para cuatro algoritmos: *IDW*, el mejor resultado obtenido por Kriging (de ahora en adelante *KRG**), *SVM* y *LSVM*.

3. Experimentación y Resultados

En esta sección se comparan los resultados obtenidos por los algoritmos propuestos (*IDW*, *KRG**, *SVM* y *LSVM*). Para ello se utilizan como medidas de calidad los resultados de las Ecuaciones 1, 2 y 3 obtenidos por cada técnica.

Los datasets empleados en el experimento están conformados por variables medidas en 7 fincas para 3 tipos de uva. Para diferenciar una misma variable que ha sido medida en diferentes fincas, o en la misma finca pero para distintos tipos de uva, se hace uso de subíndices que acompañan al nombre de la variable, tales como *C-CS* (Cobos - Cabernet Sauvignon), *C-M* (Cobos - Malbec), *LD-M* (Las Divas - Malbec), *AA-M* (Agrícola Altamira - Malbec), *TM-M* (Teresa Mosso - Malbec), etc. Es por eso que algunas de éstas variables, como ser BCN y RDP, se encuentran en varias filas de la Tabla 3. La Tabla 3 reporta los valores para la *Media del Error Absoluto (MAE)*, *Desviación Estándar del Error Absoluto (SDAE)* y la *Raíz del Error Cuadrático Medio (RMSE)* obtenidos por los algoritmos *IDW*, *KRG**, *SVM* y *LSVM*. Los valores resaltados en negrita representan el menor error obtenido por los cuatro algoritmos para esa variable.

En la Tabla 3 se puede observar que los algoritmos de aprendizaje, en general, obtuvieron mejor desempeño frente a sus competidores directos (*IDW* y *KRG**). Sobre un total de 25 datasets los algoritmos de aprendizaje lograron muy buenos resultados, destacándose *LSVM* como el mejor en 17 oportunidades para MAE, 14 para SDAE y 16 para RMSE. Esto se puede ver resumido en la Figura 2. Es importante resaltar que los algoritmos de aprendizaje también reducen la SDAE, situación deseable en problemas de interpolación. Por último, en la Tabla 3 también se hace evidente el caso en el que *Kriging* no converge a una solución (celdas con valor *NA*), situación que, como se explicó anteriormente, requiere de intervención humana para ajustar manualmente algunos parámetros en el variograma de forma que pueda completar el proceso de interpolación.

A modo ilustrativo la Figura 3 muestra los mapas que se obtienen luego de la interpolación para cada uno de los algoritmos propuestos sobre la variable RDP de la finca Teresa Mosso, para el tipo de uva Malbec. Las cruces indican los puntos del conjunto sobre el que se realizó el testeo, mientras que las burbujas indican la magnitud del error absoluto entre el valor real y el predicho para cada punto de testeo. Para esta variable la técnica *LSVM* obtiene los valores mas pequeños para cada una de las medidas de calidad propuestas (i.e. MAE,

Tabla 3. MAE, SDAE, RMSE obtenidos por los algoritmos *IDW*, *KRG**, *SVM* y *LSVM* para distintas variables vitícolas.

Variables	MAE				SDAE				RMSE			
	IDW	KRG*	SVM	LSVM	IDW	KRG*	SVM	LSVM	IDW	KRG*	SVM	LSVM
<i>BCW_{C-CS}</i>	15.46	15.96	15.47	13.63	9.402	9.486	10.25	9.432	18.03	18.56	18.48	16.48
<i>BCW_{C-M}</i>	20.98	21.49	23.24	19.49	15.48	15.32	16.16	14.39	25.99	26.31	28.23	24.16
<i>BCW#1_{F-C}</i>	16.18	NA	15.21	13.54	12.61	NA	11.43	10.02	20.33	NA	18.86	16.69
<i>BCW#2_{F-C}</i>	3.267	3.153	2.306	1.126	5.378	4.532	4.081	2.094	6.182	4.746	4.602	2.333
<i>BCW_{S-M}</i>	31.50	NA	30.41	32.04	44.21	NA	44.14	42.37	53.70	NA	53.01	52.57
<i>BUDSV_M</i>	10.12	10.17	10.39	9.944	16.78	15.63	17.88	17.57	18.67	17.81	19.69	19.21
<i>BWH_{S-M}</i>	26.73	NA	30.74	28.91	43.32	NA	43.55	42.58	50.31	NA	52.73	50.91
<i>BXB_{S-M}</i>	23.23	24.61	22.78	22.24	26.02	25.51	23.49	23.80	34.57	33.66	32.44	32.29
<i>DDTV_M</i>	0.026	0.026	0.025	0.026	0.023	0.023	0.021	0.021	0.035	0.034	0.033	0.033
<i>LENV_M</i>	0.012	0.013	0.010	0.010	0.009	0.009	0.007	0.007	0.014	0.015	0.012	0.012
<i>MADV_M</i>	1.198	1.167	1.200	1.129	0.688	0.696	0.600	0.521	1.373	1.349	1.334	1.238
<i>PCLAF_C</i>	0.210	NA	0.259	0.208	0.358	NA	0.467	0.365	0.408	NA	0.524	0.412
<i>PDPAA_M</i>	151.6	165.3	151.3	152.7	127.6	118.1	129.1	127.7	197.0	202.2	197.7	198.0
<i>RDPA_{A-M}</i>	6.209	6.254	6.258	5.736	5.337	5.509	5.314	5.154	8.139	8.284	8.162	7.663
<i>RDPF_C</i>	1.069	NA	2.655	1.346	3.130	NA	4.388	3.331	3.236	NA	5.039	3.518
<i>RDPLD_M</i>	8.548	8.284	8.150	8.047	7.512	6.896	8.163	8.216	11.35	10.75	11.50	11.46
<i>RDPTM_M</i>	9.503	9.163	9.330	8.701	7.110	6.646	6.041	5.878	11.79	11.21	11.05	10.44
<i>RDPV_M</i>	20.875	NA	21.26	20.86	12.56	NA	10.53	10.50	24.19	NA	23.60	23.23
<i>RDP#1_{C-CS}</i>	7.051	7.415	7.623	7.560	6.344	6.236	6.191	5.994	9.424	9.631	9.765	9.594
<i>RDP#1_{C-M}</i>	14.51	NA	14.00	13.51	11.96	NA	11.73	10.14	18.74	NA	18.19	16.83
<i>RDP#2_{C-CS}</i>	8.924	8.772	9.921	9.223	7.650	8.394	7.601	7.746	11.68	12.06	12.43	11.97
<i>RDP#2_{C-M}</i>	17.05	17.19	17.67	17.06	13.27	13.33	14.49	12.59	21.53	21.68	22.77	21.13
<i>SHCV_M</i>	22.79	23.11	23.17	21.73	14.53	14.62	14.39	14.96	26.54	26.85	26.79	25.85
<i>SHOOTV_M</i>	17.82	NA	19.25	15.87	14.09	NA	14.49	11.82	22.16	NA	23.55	19.35
<i>SXLV_M</i>	0.011	0.011	0.012	0.008	0.008	0.011	0.007	0.006	0.014	0.015	0.013	0.010

SDAE y RMSE), situación que se ve reflejada en las burbujas de la Figura 3 (d). Además la figura resalta que tanto *Kriging* como *SVM* generan mapas de regiones suaves a costa de una menor calidad de interpolación, mientras que para *LSVM* se pueden observar regiones más granularizadas, producto de la construcción de múltiples modelos locales (uno por cada punto a estimar) en lugar de un único modelo global.

Debido a la variabilidad espacial inherente de la tierra y del cultivo, uno de los objetivos que persigue la *Agricultura de Precisión* es la *zonificación del cultivo* y su tratamiento particular, ya que la administración individual de pequeñas áreas o zonas con rendimiento similar es altamente preferible frente a la administración homogénea de grandes campos ([Bramley, 2009]). En este trabajo se priorizó la calidad del modelo aprendido mediante la minimización del error, para la cual *LSVM* resulta en los mejores modelos. En la práctica es importante incorporar otras medidas de error no locales como ser, por ejemplo, cantidad de zonas generadas y suavizamiento de zonas. Tal como es esperado en algoritmos que no contemplan este tipo de *restricción no local*, *LSVM* resulta en modelos muy granularizados a pesar de minimizar el error, es decir, un número excesivo de zonas.

En la Figura 4 se observan comparativas de las medidas de calidad para cuatro variables (*RDPF_C*, *RDPLD_M*, *BCW#2_{F-C}*, *SXLV_M*). Ya que el objetivo de este trabajo es comparar *SVM* y *LSVM* contra sus competidores *IDW* y *Kriging*, se han resumido los mejores resultados de los dos últimos bajo la etiqueta *COMP** a fin de hacer más fácil el análisis de los resultados. De

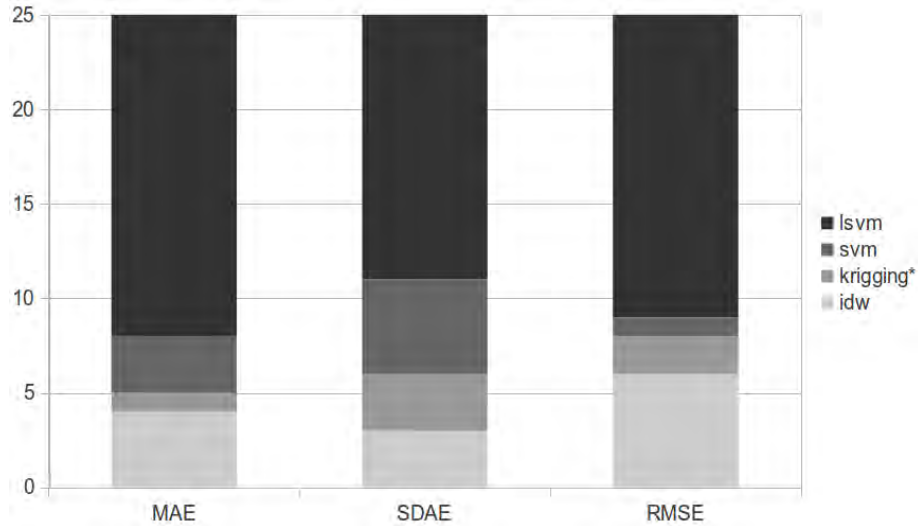


Figura 2. Número de oportunidades en las que cada técnica obtuvo mejor calidad para cada una de las medidas propuestas (MAE, SDAE y RMSE).

esta manera, si *IDW* obtuvo mejor calidad que *Kriging* se toma ese valor para *COMP** y viceversa.

Las comparativas en la Figura 4 (a) y (b) son casos para los que *IDW* o *KRG** alcanzaron mejores calidades (etiquetado como *COMP**), mientras que las figuras (c) y (d) son casos para los que *SVM* y *LSVM* lograron una calidad de predicción superior. Como se puede apreciar en (a) y (b) los resultados de *LSVM* se encuentran muy cerca del valor obtenido por *COMP**, mientras que en (c) y (d) las mejoras de *LSVM* frente a *COMP** son cercanas al 50% en (c) y aproximadas al 40% en (d). Observando la Tabla 3 se puede corroborar que en la mayoría de los casos en los que *COMP** obtiene mejores resultados, los algoritmos de aprendizaje obtienen resultados muy cercanos.

4. Conclusiones y Trabajo Futuros

Los resultados presentados en este trabajo preliminar motivan a continuar con la investigaciones sobre la aplicación de algoritmos de aprendizaje que permitan mejorar aún más la calidad de las predicciones. Algunas ideas para futuras investigaciones sobre el tema abarcan continuar con las investigaciones sobre *SVM* y *LSVM* e incluir nuevas técnicas y algoritmos avanzados de aprendizaje de máquinas, como ser *Redes Neuronales Artificiales*, así como aplicar y adaptar estas técnicas de modelización en ambientes multivariados para mejorar la predicción de productividad y calidad de cultivos vitivinícolas.

Como se explico en la Sección 1 un problema con *Kriging* es que asume una media espacial nula. Esto puede resolverse aplicando *Kriging* al resultado

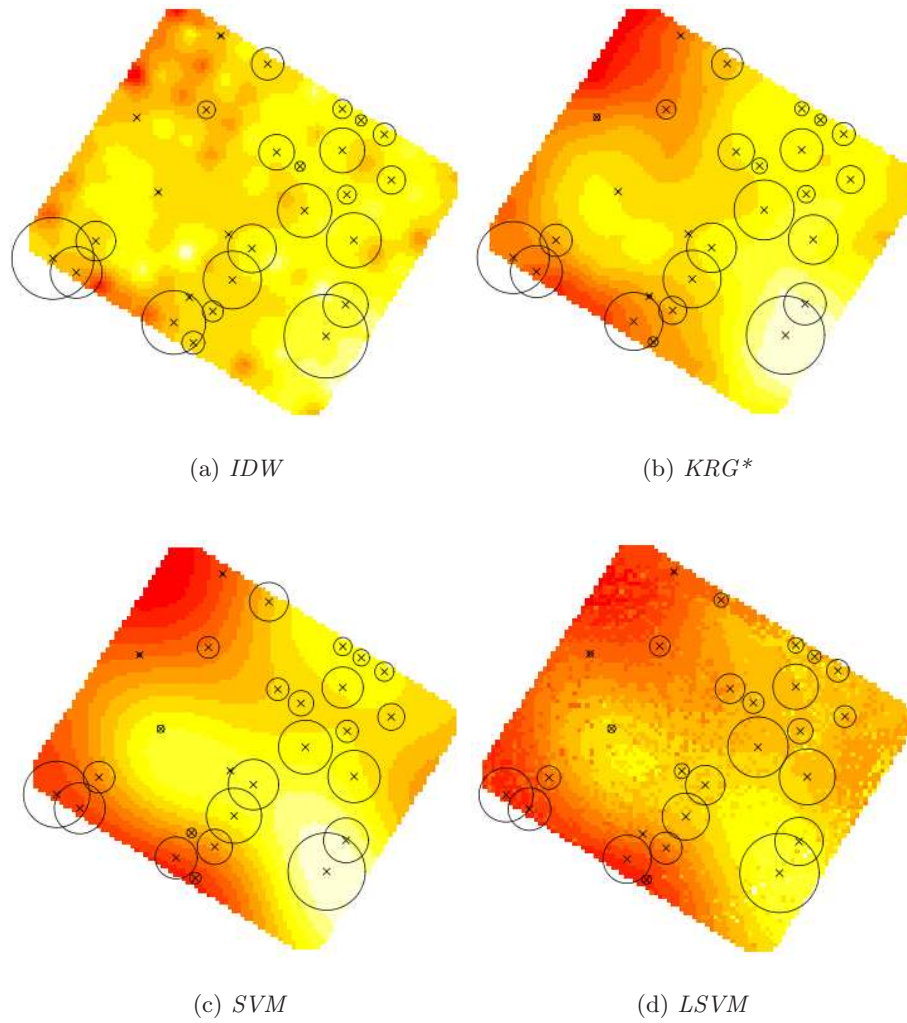


Figura 3. Mapas de interpolación, puntos de testeo (creces) y errores absolutos (burbujas) para la variable RDP perteneciente a la finca Teresa Mosso, tipo de uva Malbec.

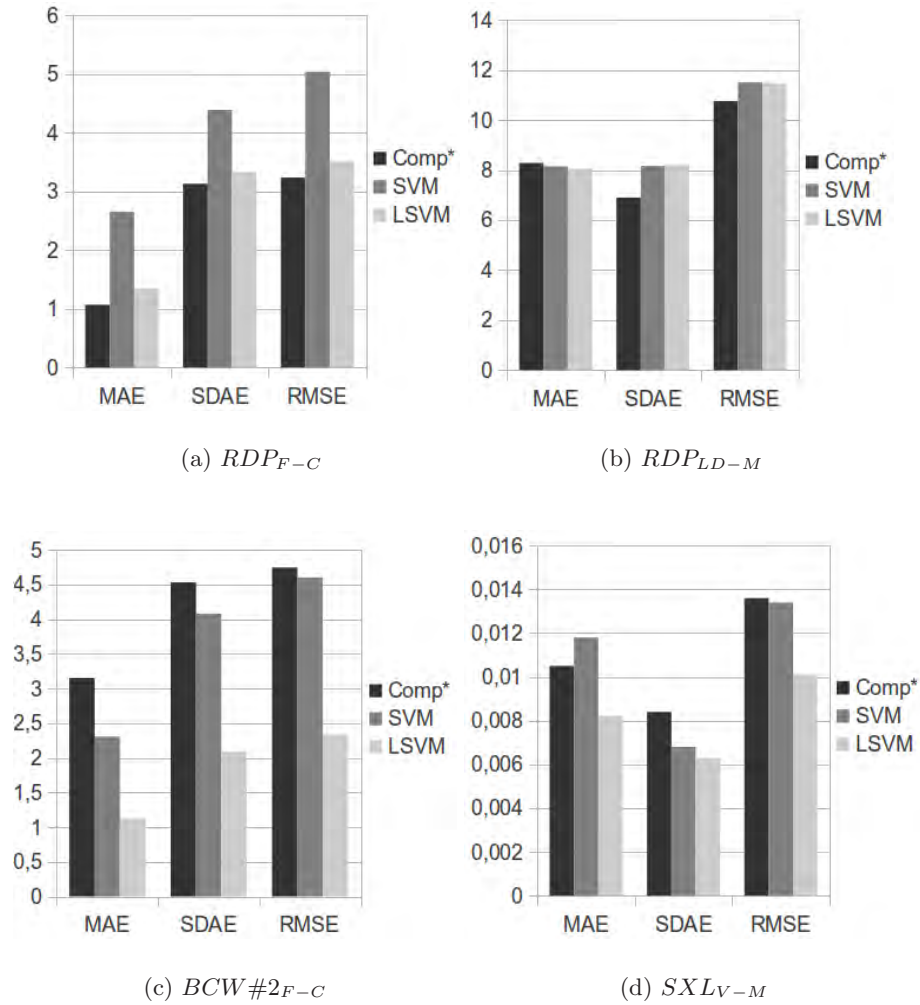


Figura 4. Comparativa de las medidas de calidad entre el mejor valor obtenido por IDW o KRG^* (etiquetado como $COMP^*$), SVM y $LSVM$ para cuatro variables.

de restarle a los valores medidos la media espacial. Esta solución requiere sin embargo conocer esta media espacial, lo que a su vez requiere de un modelo del proceso subyacente. Este modelo podría ser obtenido desde los datos vía *SVM* para estimar la media espacial y aplicar finalmente *Kriging*, logrando automatizar el proceso completo.

5. Agradecimientos

Los datos necesarios para la realización de los experimentos y la evaluación de algoritmos han sido provistos por la empresa *XoomCode S.A.*. Esta empresa posee un convenio con el laboratorio de Inteligencia Artificial DHARMA, en el cual se comprometen a facilitar, bajo ciertas condiciones de confidencialidad, los datos obtenidos de mediciones pasadas y futuras.

Referencias

- Arnó Satorra *et al.*, 2009. J. Arnó Satorra, J.A. Martínez Casasnovas, M. Ribes Dasi, and J.R. Rosell Polo. Review. precision viticulture. research topics, challenges and opportunities in site-specific vineyard management. *Spanish Journal of Agricultural Research*, 2009, vol. 7, núm. 4, p. 779-790, 2009.
- Bishop, 2009. C.M. Bishop. *Pattern recognition and machine learning*. Springer, 2009.
- Bottou and Vapnik, 1992. L. Bottou and V. Vapnik. Local learning algorithms. *Neural computation*, 4(6):888-900, 1992.
- Bramley and Lamb, 2003. RGV Bramley and DW Lamb. Making sense of vineyard variability in australia. In *Proc. Internat. Symp. on Precision Viticulture, Ninth Latin American Congr. on Viticulture and Oenology*, pages 35-54, 2003.
- Bramley, 2009. RGV Bramley. Lessons from nearly 20 years of precision agriculture research, development, and adoption as a guide to its appropriate application. *Crop and Pasture Science*, 60(3):197-217, 2009.
- Campbell, 2001. C. Campbell. An introduction to kernel methods. *Studies in Fuzziness and Soft Computing*, 66:155-192, 2001.
- Cressie, 1990. N. Cressie. The origins of kriging. *Mathematical Geology*, 22(3):239-252, 1990.
- Cressie, 1992. N. Cressie. Statistics for spatial data. *Terra Nova*, 4(5):613-617, 1992.
- Gilardi and Bengio, 2000. N. Gilardi and S. Bengio. Local machine learning models for spatial data analysis. *Journal of Geographic Information and Decision Analysis*, 4(1):11-28, 2000.
- Kanevski and Canu, 2000. M. Kanevski and S. Canu. Spatial data mapping with support vector regression. *IDIAP Research Report, RR-00-09*, 2000.
- Matheron, 1963. G. Matheron. Principles of geostatistics. *Economic geology*, 58(8):1246-1266, 1963.
- Mitchell, 1997. T.M. Mitchell. *Machine learning*. McGraw-Hill, 1997.
- Schölkopf *et al.*, 2000. B. Schölkopf, A.J. Smola, R.C. Williamson, and P.L. Bartlett. New support vector algorithms. *Neural computation*, 12(5):1207-1245, 2000.
- Shepard, 1968. D. Shepard. A two-dimensional interpolation function for irregularly-spaced data. In *Proceedings of the 1968 23rd ACM national conference*, pages 517-524. ACM, 1968.

Taylor and Whelan, 2005. J. Taylor and B. Whelan. A general introduction to precision agriculture. *Grains Research and Development Corporation*, www.usyd.edu.au/su/agric/acpa, 2005.