

# MODELACIÓN DE °BRIX Y PH EN UVA VINÍFERA MEDIANTE IMÁGENES SATELITALES. VALLE DE COLCHAGUA, CHILE

## MODELING °BRIX AND PH IN WINE GRAPES FROM SATELLITE IMAGES IN COLCHAGUA VALLEY, CHILE

Sandra Fredes\*, Luis Ángel Ruiz, Jorge Abel Recio

Geo-Environmental Cartography and Remote Sensing Group (CGAT), Universitat Politècnica de València, Camino de Vera s/n, 46022 Valencia, España. [sanfre@doctor.upv.es](mailto:sanfre@doctor.upv.es); [laruiz@cgf.upv.es](mailto:laruiz@cgf.upv.es); [jrecio@cgf.upv.es](mailto:jrecio@cgf.upv.es)

### Abstract:

In order to monitor the ripeness and composition of wine grape berries and establish an optimal harvest date, the determination of °Brix and pH is vital. This research includes the study of two wine grapes harvests seasons of Cabernet Sauvignon variety: 2017 and 2018. Field data was periodically taken, allowing to follow the phenological state of the vine. Incorporating technological solutions to the fruit sampling process, such as Sentinel-2 images, permits optimizing a handcrafted procedure and gives the possibility of having a more detailed view of the plots. From the images, 12 variables were obtained, composed of 8 bands and 4 spectral indices, which were related to variables extracted from field samples. The °Brix modeling presents an R<sup>2</sup> of 69% and 73% in the 2017 and 2018 seasons, respectively. In pH modeling, the 2017 season had low R<sup>2</sup> results, reaching 43%, which then improves considerably in the 2018 season, reaching 63.8%. By choosing a model that allows defining the variability of the plot and the possible early or late ripening areas of the vineyard, is not only very useful but also very valuable to reach a constant improvement in production and hence in the wine quality.

**Key words:** °brix, pH, Sentinel-2, precision of viticulture, remote sensing

### Resumen:

Con el fin de monitorear la madurez y composición de las bayas de uva vinífera y determinar una fecha óptima de cosecha, es vital la determinación de °Brix y pH. Esta investigación comprende el estudio de dos temporadas de cosecha de uva vinífera de variedad Cabernet Sauvignon: 2017 y 2018. Periodo en el cual se tomaron periódicamente datos de campo que permitieron seguir el estado fenológico de la vid hasta el momento de la cosecha y posterior vinificación. Incorporar soluciones tecnológicas, como el uso de imágenes satelitales, en este caso Sentinel-2, al proceso de muestreo de fruta, permite optimizar un proceso artesanal, dando la posibilidad de tener una visión más detallada del cuartel, lo que hace más eficiente el trabajo de terreno. Desde las imágenes se obtuvieron 12 variables compuestas por 8 bandas y 4 indicadores (NDVI, NDMI, Clorofila y GNDVI) que se relacionaron con variables extraídas de muestreos de campo. Con dichos datos se seleccionó el mejor modelo de regresión lineal múltiple, utilizando 3 variables para predecir °Brix y pH. La modelación de °Brix presenta un coeficiente de determinación R<sup>2</sup> de 69% y 73% en las temporadas 2017 y 2018, respectivamente. En el caso de la modelación de pH, la temporada 2017 tiene bajos resultados de R<sup>2</sup>, alcanzando un 43%, el cual mejora considerablemente en la temporada 2018, alcanzando un 63.8%. Determinar un modelo que permita definir la variabilidad de la parcela y, por tanto, las posibles zonas de maduración temprana o tardía del viñedo, es de gran utilidad para concretar una mejora en la producción y por ende en la calidad del vino.

**Palabras clave:** °brix, pH, Sentinel-2, viticultura de precisión, remote sensing

## 1. Introducción

Según los últimos datos presentados por la Organización Internacional de la Uva y el Vino (OIV) en abril de 2020, la superficie vitícola mundial estaría sobre los 7,5 millones de hectáreas considerando la superficie de uvas destinada a vinificación, uva de mesa y uvas pasas (Buzzetti 2018). En Chile, la superficie total de viñas para vinificación ocupa actualmente más de 192 mil hectáreas, las cuales tienen un potencial de producción de vino cercano a los 1.200 millones de litros. Actualmente Chile es el segundo productor de vinos de América y cuarto exportador mundial de vinos, siendo superado sólo por países europeos de vasta trayectoria en materias vitivinícolas, como Francia, España e Italia. Esta superficie se encuentra principalmente, en las regiones

de O'Higgins y del Maule, concentrando más del 72% de la superficie nacional. Dentro de la industria vitivinícola, Viña Montes, empresa propietaria de los viñedos en los que se ha desarrollado este estudio, tiene un total de 720 hectáreas de vid y exporta un 93% de su producción (Müller 2004; Lima 2015).

La recopilación de datasets espaciales georreferenciados, como las imágenes satelitales, permite a los viticultores optimizar el proceso de toma de decisiones minimizando la variabilidad del rendimiento, así como también aprovechar esta variabilidad para aplicar la cosecha selectiva para aumentar la calidad del vino (Ammoniacci *et al.* 2021). La producción de vino de calidad requiere una adecuada selección de fruta para ser incorporada al proceso (Martinez-Casasnovas *et al.* 2010; Perez Quezada 2006). En la literatura destaca el

\* Corresponding Author: Sandra Fredes, [sanfre@doctor.upv.es](mailto:sanfre@doctor.upv.es)

uso del NDVI (Normalized Difference Vegetation Index) para gestionar una cosecha dirigida y relacionar con él factores de calidad como azúcar y acidez. Se ha comprobado que el valor de NDVI está relacionado linealmente con el área foliar (Johnson *et al.* 2003), maduración de la fruta, infestación y enfermedades, estatus hídrico (Van Leeuwen *et al.* 2004), contenido de antocianos (Hall *et al.* 2003), taninos en la piel de la uva (Cortell *et al.* 2005), evaluación de rendimiento (Cunha *et al.* 2010; Martínez-Casasnovas *et al.* 2010) y propiedades de la madurez de la fruta (Martínez-Casasnovas *et al.* 2012).

En los últimos años, la disponibilidad de datos gratuitos de satélites como Sentinel-2 ha generado un mayor interés en su uso potencial en la viticultura (Atzberger 2013; Khaliq *et al.* 2019; Sozzi *et al.* 2020), convirtiéndose en una solución atractiva para el monitoreo espacio temporal de muchos cultivos (Borgogno-Mondino *et al.* 2018), entregando información oportuna, sinóptica, rentable y repetitiva (Atzberger 2013) y en el potencial que tiene su uso en operaciones de manejo de la vid, como el deshierbe y la poda (Devaux *et al.* 2019), visibilizando principalmente la variabilidad intraparceldaria, la cual ha sido uno de los focos de la viticultura de precisión, debido a que las prácticas agrícolas se aplicaban tradicionalmente de manera uniforme (Bramley 2010), con la misma intensidad o dosis en operaciones como poda, fertilización, riego o tratamientos fitosanitarios (Arnó *et al.* 2009). Según Urretavizcaya *et al.* (2014) la variabilidad tiene implicaciones en la calidad de la uva y en la rentabilidad. Por ello, la identificación y la caracterización espacial de dicha variabilidad, la interpretación de su significado enológico, así como la posibilidad del manejo diferencial de dicha variabilidad, constituyen los principales objetivos de la Viticultura de Precisión (Matese and Di Gennaro 2015; Pastonchi *et al.* 2020).

Identificar la variabilidad intraparceldaria tiene implicaciones en la calidad del vino, así como en el control del proceso de maduración (Bramley 2010), información esencial durante la vendimia, que dependiendo del tipo y tamaño del viñedo, se realiza generalmente combinando tecnología de vendimia manual y mecanizada. Las parcelas predefinidas se evalúan semanalmente después del envero con el fin de medir el contenido de azúcar y ácido, estos son los parámetros más comunes en los que se basan los viticultores para determinar el momento correcto para la cosecha (Lima 2015). Definir cuándo y qué cuarteles serán cosechados se basa únicamente en la evaluación organoléptica que se realiza en terreno diariamente, tal como lo grafica Sun *et al.* (2017), las observaciones de campo de las etapas de crecimiento de la vid son demasiado escasas para capturar completamente la variabilidad espacial de las condiciones de la vid. Por lo tanto, mejorar el rendimiento del viñedo y la calidad de la uva a través de un conocimiento adecuado de la variabilidad espacial del viñedo para reducir los costos y el impacto ambiental es uno de los actuales desafíos (Khaliq *et al.* 2019; Pastonchi *et al.* 2020). Optimizar la producción de vino requiere comprender los factores que influyen en su variabilidad espacial y temporal, el suelo, el clima, la fisiología vegetal y el manejo agrícola que son responsables de las diferentes expresiones fisiológicas de la vid (Priori *et al.* 2019). La variabilidad en el viñedo es un problema estudiado ampliamente en Australia,

Francia y España (Taylor *et al.* 2005; Arnó *et al.* 2005), Chile (Mashalaba *et al.* 2020), Nueva Zelanda (Trought *et al.* 2008) y Canadá (Reynolds and Rezaei 2014), entre otros, confirmando que la variabilidad es un factor a considerar para mejorar la calidad del vino. El NDVI, uno de los índices de vegetación más utilizados (Pastonchi *et al.* 2020), utiliza las bandas espectrales visible (Rojo) e infrarrojo cercano (NIR), que están estrechamente relacionadas con las características vegetativas y productivas del cultivo (Khaliq *et al.* 2019).

La calidad del vino está estrechamente relacionada con la calidad de la fruta, y el follaje del cultivo está relacionado con la interacción del suelo, el clima, el estado del agua y el manejo agronómico, que son factores que afectan directamente la calidad de la fruta. Por lo tanto, podemos plantear la hipótesis de que el uso de índices espectrales derivados de imágenes Sentinel-2 puede proporcionar información indirecta pero valiosa sobre aquellas variables medidas directamente en la fruta y que son indicadores de la calidad del vino, como el azúcar y la acidez. Además, conocer su distribución espacial en momentos clave contribuiría a planificar mejor la cosecha diferencial para la producción de vino de calidad. Este estudio tiene como objetivo contribuir a la gestión selectiva de los cultivos de vid, mediante el uso de imágenes satelitales de resolución espacial media (Sentinel-2) desde una doble perspectiva: (i) el análisis de bandas espectrales e índices para generar modelos que permitan estimar °Brix (concentración de azúcar en la baya) y pH y (ii) explorar el uso de imágenes Sentinel-2 para diferenciar y mapear la variabilidad del cultivo de la vid, con el fin de identificar áreas potenciales de maduración temprana o tardía. Esto implicaría un beneficio directo para la cosecha selectiva y, en consecuencia, supondría una mejora sustancial de la producción y la calidad del vino.

## 2. Materiales y Métodos

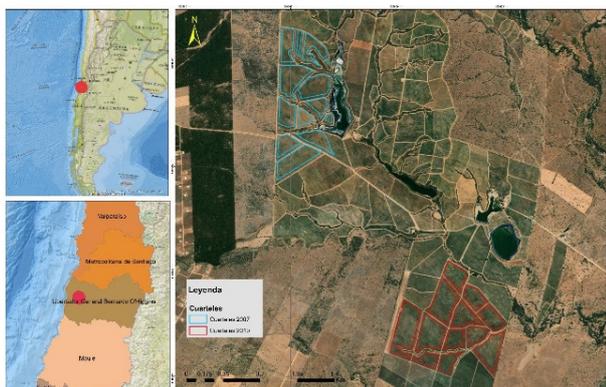
Esta investigación comprende el estudio de datos de campo de dos temporadas de cosecha de producción de uva vinífera: 2017 y 2018. Se estudiaron dos lotes (grupo de cuarteles) de variedad Cabernet Sauvignon, donde se tomaron periódicamente datos de campo que permitieron seguir el estado fenológico de la vid hasta el momento de la cosecha y posterior vinificación.

### 2.1. Área de estudio

Viña Montes tiene una superficie de 720 ha de vid. La plantación en estudio está ubicada en Marchigue, valle de Colchagua en Santa Cruz, VI región, en Chile (Fig. 1), se conoce como Arcángel, la cual tiene una superficie total plantada de 499 has, conformadas por lotes de diversas variedades: Cabernet Sauvignon, Syrah, Carmenere, entre otros; y diversas categorías de calidad.

El área de interés en la cual se desarrolla este estudio está formada por 23 cuarteles, un cuartel corresponde al polígono que encierra un grupo de hileras de una misma cepa. En este caso se agrupan en 2 grupos o lotes: 12 cuarteles formados por 13 polígonos que suman un total de 64.8 has y 11 cuarteles formados por 12 polígonos que suman 71 has, correspondientes a plantaciones de los años 2007 y 2010 respectivamente, según se observa en la Figura 1. Los lotes están conformados un 100% por la variedad Cabernet Sauvignon, categoría Alfa, categoría

intermedia de calidad que corresponde a la mayor producción de Viña Montes, plantados según un patrón de 2x1.



**Figura 1:** Mapas de ubicación general (izq.) y de emplazamiento de los cuarteles Cabernet Sauvignon (der.); polígonos cian corresponden a plantaciones del año 2007 y polígonos rojos a plantaciones del año 2010. Imagen de Fondo: BaseMap ArcGIS, World Imagery.

Las coordenadas en Proyección UTM, WGS 84 Huso 19S, que hacen referencia al centro de cada uno de los lotes son: Plantación 2007: ESTE: 254096,003 m; NORTE: 6197606,610 m; Plantación 2010: ESTE: 255503,426 m; NORTE: 6195483,135 m.

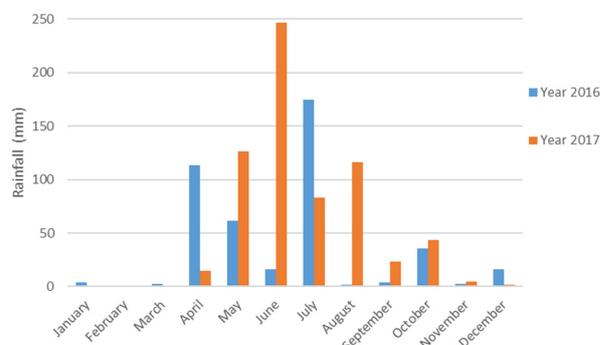
### 2.1.1. Ciclo de la vid y meteorología de la zona

Gran parte de la producción vitivinícola en el mundo, se desarrolla en climas de tipo mediterráneo, caracterizado por altas temperaturas en la época estival, una alta intensidad luminosa y niveles de humedad ambiente que disminuyen fuertemente a lo largo del día (Chaves *et al.* 1987). Precisamente, en la zona de estudio predomina un clima templado de tipo mediterráneo cálido (Uribe and Catalan 2016) con una estación seca de seis meses y un invierno lluvioso con una precipitación total anual entre 400 y 600 mm. Los suelos son de origen aluvial, con texturas franco-limosas (Giraldo 2017).

El ciclo puede tener algunas variaciones que se ven influenciadas por diferencias en las condiciones de temperatura y precipitaciones (Pardo 2016). Un aumento significativo en las temperaturas, sumado a una disminución en las precipitaciones, provocaría un mayor estrés hídrico en las plantas. Por otro lado, un incremento de las temperaturas promedio y la reducción de la oscilación térmica, influye en el aroma de los variedades y el color de los vinos. Así mismo, los otoños cada vez más secos y las lluvias ocasionales asociadas a eventos intensos, implicarían mayores requerimientos de riego para los viñedos (Giraldo 2017).

La influencia de las precipitaciones en el ciclo fenológico de la vid requiere la acumulación de agua caída el año previo. En el caso de las temperaturas, su influencia es directa durante el mismo año de la vendimia. El ciclo fenológico de 2017 está marcado por las precipitaciones del año 2016, escasas en comparación con las precipitaciones acumuladas del año 2017 (ciclo fenológico de la vid 2018), que se duplicaron con relación a 2016 (Fig. 2). Durante la temporada 2018, la temperatura del aire se presentó relativamente más baja que el año 2017 durante el ciclo de maduración de la vid.

La diferencia de temperaturas alcanzó 1.99 °C lo que se traduce en un 11% más bajo. La radiación solar durante el ciclo, también se presentó levemente más baja alcanzando un promedio de diferencias de -5.8% según se aprecia en la Figura 2, la cual muestra una comparación quincenal de la temperatura del aire y la radiación solar, en ambas temporadas. En la cual se aprecian las mayores diferencias justamente en pleno verano antes del invierno.



**Figura 2:** Precipitación Mensual 2017 y 2018.

## 2.2. Datos

### 2.2.1. Imágenes satelitales

La Figura 3 muestra la fecha de adquisición de un conjunto de 16 imágenes. La constelación Sentinel -2 está formada por 2 satélites de órbita heliosíncrona cuya resolución temporal es de 10 días por satélite o 5 en conjunto. Ambos satélites llevan un sensor de imágenes multispectrales (MSI) capaz de adquirir imágenes en 13 bandas espectrales, desde 433 nm hasta 2280 nm. La banda del rojo (665 nm) y del infrarrojo cercano (842 nm) son de particular interés para la aplicación agrícola, ya que permiten recuperar varios índices de vegetación a 10 m de resolución espacial (Sozzi *et al.* 2020). Las imágenes Sentinel-2, fueron descargadas directamente desde la plataforma *Copernicus Open Access Hub*.

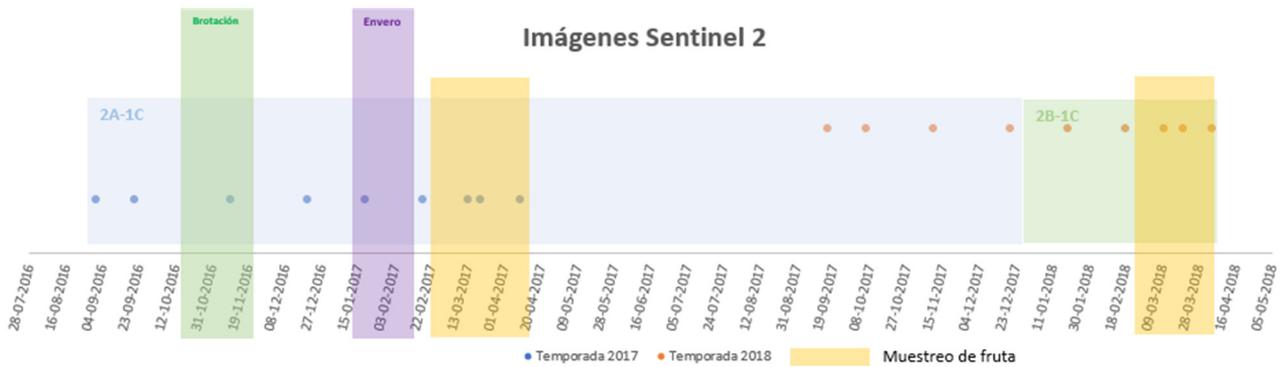
Las imágenes Sentinel 2A y Sentinel 2B y se descargaron en nivel de procesamiento 1C, las cuales fueron corregidas atmosféricamente para obtener reflectividades en superficie, mediante la aplicación Sen2cor en el entorno de SNAP. Las fechas y nivel de procesamiento se aprecia en la Figura 3.

### 2.2.2. Datos de campo

El invierno es una etapa muy importante para el enólogo, ya que la maduración comienza con el invierno. La duración de esta etapa es variable y puede ir de 20 a 50 días según el punto de cosecha deseado. A partir de este momento, el agua, los azúcares y los compuestos nitrogenados son transportados al grano. Las bayas comienzan a aumentar peso y tamaño, por acumulación de sustancias nutritivas (principalmente azúcares) y agua, alcanzando su tamaño máximo. Al fin de la etapa la semilla está apta para germinar, se le llama también madurez fisiológica (Catania and Avagnina 2007). Para cuantificar la concentración de azúcar, se utiliza un refractómetro con compensación automática de temperatura, rango 0-32% Brix, como se colectan bayas de distintos sectores dentro del área de muestreo, el resultado se traduce como el promedio de la muestra. El

pH es la medida de la concentración de iones hidrógenos libres y es un término utilizado para determinar la acidez (Castro 2005). El manejo adecuado de la acidez y el pH es fundamental, ya que en última instancia determina la

calidad de los vinos (Forino *et al.* 2020), ya que influye en las propiedades sensoriales y equilibrio de los vinos (Picariello *et al.* 2019). Las mediciones fueron realizadas con un pHmetro.

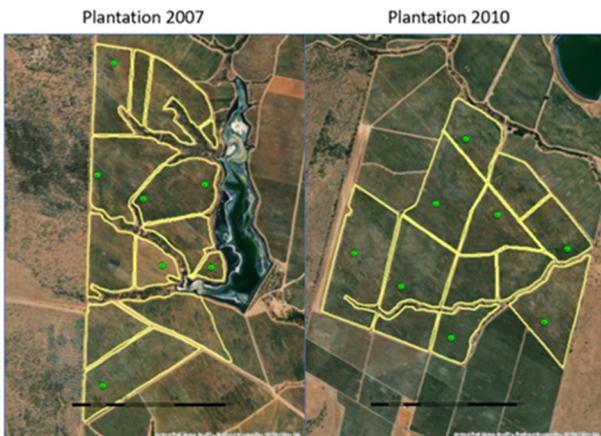


**Figura 3:** Características de las imágenes Sentinel-2 utilizadas. Caracterización del comportamiento vegetacional de la vid en ambas temporadas desde brotación (septiembre) a abril (cosecha). Se muestra simultáneamente la etapa de brotación y envero para la temporada 2017 y las fechas destinadas a muestreo de fruta en campo en ambas temporadas.

### 2.3. Métodos

#### 2.3.1. Muestreo de datos Brix y pH en campo

La ubicación geográfica de las muestras de baya se basó en el conocimiento e identificación de zonas críticas y homogéneas de calidad de producción histórica del vino. Para ello se precisó del conocimiento del técnico agrónomo de Viña Montes. Para la ubicación de las muestras se utilizó el NDVI histórico del mes de diciembre y el Modelo Digital de Elevaciones de la zona (DEM), se definieron zonas que compartieran características comunes de expresión vegetativa y topografía y luego se distribuyeron espacialmente las muestras de forma homogénea en el área de interés. De esta categorización se obtuvo la posición específica en la cual se ubicarían 15 muestras en 14 cuarteles (Fig. 4).

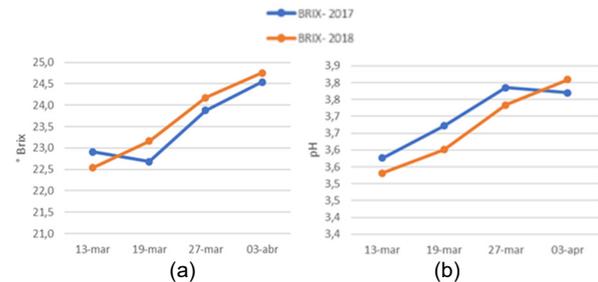


**Figura 4:** Distribución espacial de las muestras físicas de bayas (puntos verdes). Polígonos en amarillo corresponden a todos los cuarteles de variedad Cabernet Sauvignon. Imagen ArcMap.

El cuartel 7.08 muestra dos posiciones de muestreo, los cuales fueron promediados. Con equipamiento GPS, se marcó la posición central de cada muestra, desde la cual se tomó el radio para extraer las bayas a analizar. La toma de datos se realizó en un radio de 15 metros desde

la posición central, tomando un promedio de 300 bayas por punto de muestreo, las bayas son homogéneas, se escogen 5 bayas por racimo: 3 bayas de los hombros del racimo, 1 de la parte media y 1 de la parte inferior del racimo.

Las Figuras 5a y 5b, muestran la evolución de las muestras de campo °Brix (a) y pH (b) en las dos temporadas. En ellos es posible desprender que la temporada 2018 alcanzó mejores valores tanto de acumulación de azúcar como de acidez.



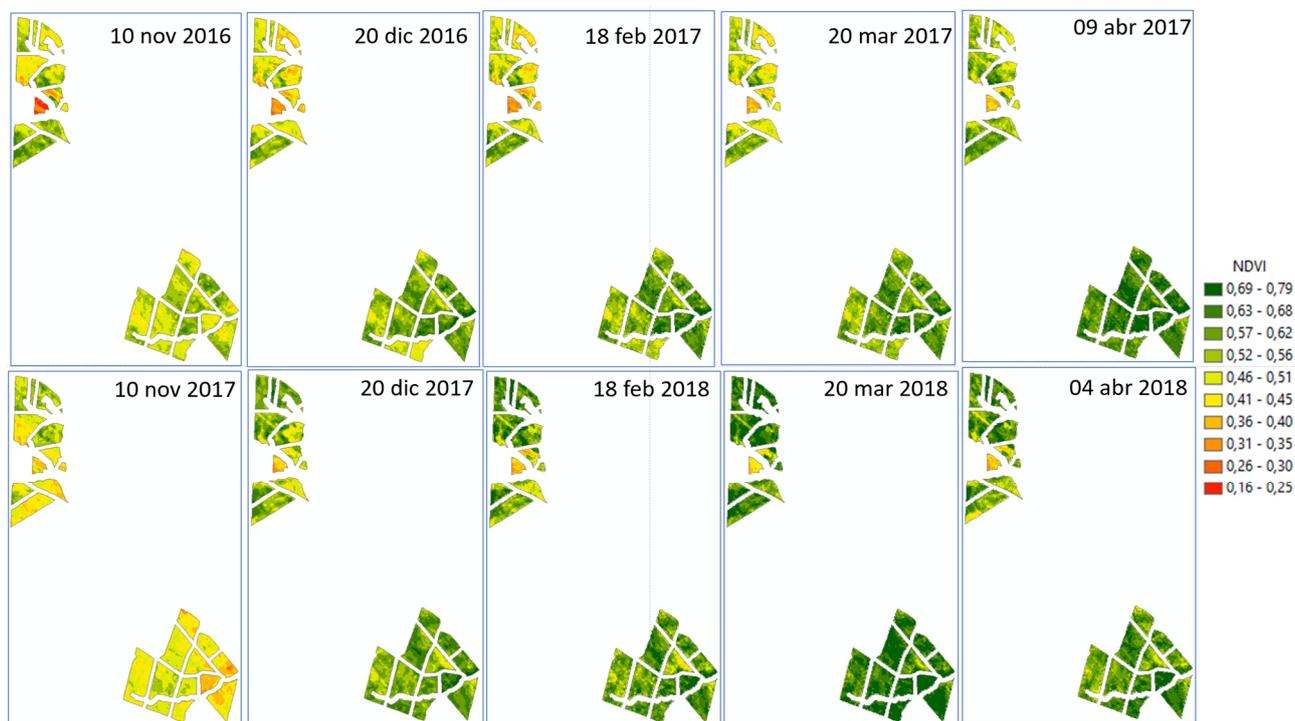
**Figura 5:** Comparación de muestras: a) de Brix; b) de pH.

#### 2.3.2. Índices espectrales

Se utilizaron imágenes Sentinel, corregidas geométrica y radiométricamente y corregistradas entre sí mediante puntos de control de terreno. En el proceso de corrección geométrica se utilizó el método del vecino más cercano y se conservó el tamaño original de pixel. La reflectancia en un pixel de 10 metros estará influenciada por el follaje, el suelo y, en un bajo porcentaje, por las bayas. Por tanto, las variaciones espectrales principales y que son objeto de interés tienen que ver con las variaciones en el follaje. Con este objetivo se escogieron 4 índices espectrales. Estos índices son de amplio uso en diversas aplicaciones agrícolas: Green Normalized Difference Vegetation Index ( $GNDVI = \frac{Nir-verde}{Nir+verde}$ ), Normalized Difference Vegetation Index ( $NDVI = \frac{Nir-Rojo}{Nir+Rojo}$ ), Normalized Difference Moisture Index ( $NDMI = \frac{Nir-Swir1}{Nir+Swir1}$ ), y Clorofila ( $Clorofila = \frac{Rojo-Azul}{Verde}$ ). En el caso del índice llamado Clorofila, se utilizan las bandas del visible, ya que este rango espectral está dominado

por las propiedades ópticas de los pigmentos fotosintéticos de las hojas (Hallik *et al.* 2017). En el caso del NDVI, utiliza las bandas NIR y SWIR1 (Sentinel 2), para determinar el contenido de humedad en el dosel (Herrera and Chuvieco 2014). Se utiliza la banda SWIR1,

correspondiente a la longitud de onda comparativamente más parecida a la banda de onda corta de Landsat, base del indicador (Brom *et al.* 2012; Gao 1996; Wang *et al.* 2011, 2013).



**Figura 6:** Representación gráfica del NDVI desde floración a cosecha para las temporadas 2017 (fila superior) y 2018 (fila inferior). Escala grafica de 10 rangos única para todas las fechas.

La visualización de comportamiento y evolución que tiene el viñedo permite dar una visión general, tanto del estado de los cuarteles como del desarrollo en ambas temporadas (Hernández *et al.* 2014). La mejor expresión vegetativa, o el máximo potencial de NDVI, se da en verano y generalmente posterior al envero empieza a modificarse el follaje y ya en el periodo de cosecha comienza a perder hojas. La Figura 6 muestra los mapas de NDVI visualizados en una escala de 10 rangos.

### 2.3.3. Modelización de °Brix y pH

Se creó una tabla de información por cada fecha de muestreo. La tabla de información incluía el nombre del cuartel, el valor de la muestra correspondiente al promedio de las bayas tomada en un radio de 15 metros alrededor de la posición central y los datos obtenidos desde las imágenes correspondientes a la fecha más próxima al muestreo. Para ello, se creó una capa vectorial de puntos correspondiente a las coordenadas de los puntos de muestreo y se realizó un buffer de 15 metros alrededor de ellos. El buffer se utilizó como un polígono desde el cual se extrajo el valor promedio de los píxeles de las 8 bandas utilizadas y de los cuatro índices.

En total 14 muestras con 12 variables independientes para determinar si existe una combinación que espectralmente explique el contenido de azúcar y el pH en las bayas. Se utilizó un modelo de regresión lineal múltiple para describir la relación entre °Brix y pH y las bandas e indicadores de las imágenes satelitales.

## 3. Resultados

### 3.1. Comparación de Coeficiente de Determinación R<sup>2</sup>

La determinación de los modelos °Brix y pH comienza con la selección del mejor modelo de regresión a partir de la combinación de múltiples variables. El modelo de regresión se obtuvo considerando las mejores variables en cada fecha. A partir de la imagen, se consideraron todos los píxeles dentro de un círculo de radio de 15 metros alrededor de la muestra de terreno. Mediante el ajuste de mínimos cuadrados ordinarios, se obtuvo la información sobre los modelos de regresión múltiple, de los cuales se derivaron los valores estadísticos de validación de cada modelo y la ecuación del modelo ajustado para cada caso. Según los resultados en °Brix, la comparación del R<sup>2</sup> en ambas temporadas muestra que, en general (Fig. 7), la temporada 2017 alcanza mejores coeficientes desde mediados de marzo con 2 variables; a diferencia de la temporada 2018 que se produce a finales de marzo. En el caso de la temporada 2017, con 3 variables en adelante, independientemente de la fecha, el coeficiente de determinación no baja del 67%.

Al enfocarse en los resultados de pH, la comparación de R<sup>2</sup> en ambas temporadas muestra una mayor estabilidad en las fechas ya que los más altos R<sup>2</sup> se concentran en el muestreo del 19 de marzo. En el caso de la temporada 2018, los R<sup>2</sup> más altos se dividen entre el 13 de marzo y a fines de este.

A diferencia de la modelación de °Brix, el caso de pH en todas las combinaciones alcanzan valores más bajos, aunque mejora discretamente durante la temporada 2018, la cual consideran el promedio de todas las fechas de muestreo con relación al número de variables tanto para °Brix como para pH.

Las estadísticas obtenidas en la modelación de °Brix y pH, se observan en las Figuras 8 y 9, la que incluye el gráfico de dispersión para los valores de los puntos de muestreo en relación con los valores observados respecto de los predichos.

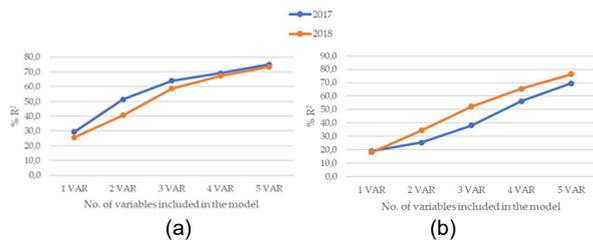


Figura 7: Promedio de coeficientes de determinación R<sup>2</sup> en las temporadas 2017 y 2018 para: a) °Brix; b) pH.

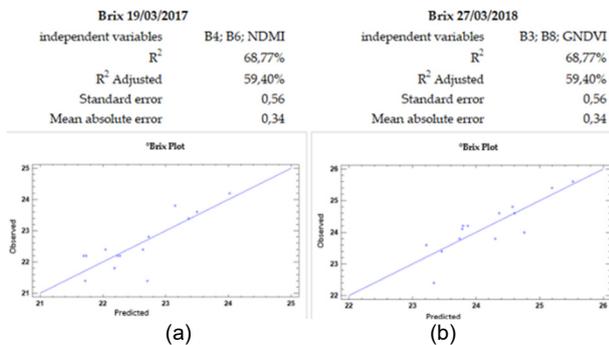


Figura 8: °Brix. Estadísticas de Regresión múltiple para las temporadas: a) 2017; b) 2018.

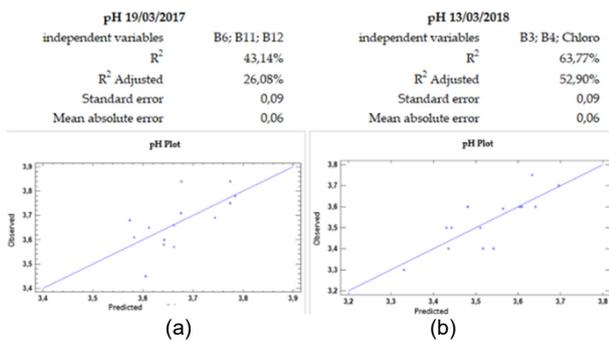


Figura 9: pH. Estadísticas de Regresión múltiple para las temporadas: a) 2017; b) 2018.

### 3.2. Modelo aplicado

Como se puede apreciar en la Tabla 1, no existe igualdad de variables utilizadas en los modelos para el caso de la modelación de °Brix, la cual incluye en ambas temporadas 2 bandas y un índice, a diferencia de lo que se obtiene en la modelación de pH, en la cual, en la primera temporada se incluyen 3 bandas y en la segunda temporada 2 bandas y un índice espectral, correspondientes a: bandas 3 (verde) y 4 (rojo) más el índice clorofila.

### 3.3. Mapas Estimados °Brix y pH

Mediante la aplicación de los modelos, se pueden obtener mapas representativos del estado de °Brix y pH en una fecha determinada, mostrando la variabilidad de cada parcela en cuanto al potencial de maduración. Esto permite, mediante el uso de un número limitado de muestras de campo e imágenes Sentinel-2, estimar la variabilidad de toda la parcela. Aunque la generación de estos mapas no elimina la adquisición de datos de campo, hace que el proceso de muestreo sea más eficiente, ya que facilita la identificación áreas claves en la madurez y por ende la determinación de dónde realizar el muestreo de campo.

En la imagen correspondiente a Brix, tanto en las temporadas 2017 como 2018 (Fig. 10), se logra apreciar la variación intraparcalaria, muy similar a lo mostrado en la imagen de NDVI. Se aprecia una relación inversa entre Brix y vigor, condición ratificada por Bonilla *et al.* (2015) quien indica que la mayoría de los estudios relacionados a vigor y calidad de uva reflejan que las cepas de alto vigor presentan menos contenido de antocianinas que las cepas de vigor bajo, condición que toma fuerza si se considera lo indicado por Peña (2005), los antocianos son compuestos glucosidados, por tanto la presencia de los azuceres para la formación de antocianos es imprescindible (Liu *et al.* 2018).

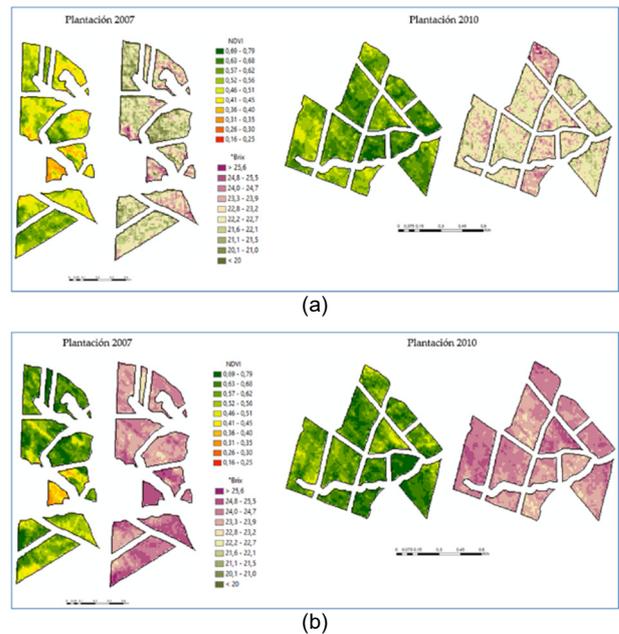


Figura 10: Mapa de modelación de °Brix para las temporadas: a) 2017; b) 2018.

En el caso de los mapas de pH (Fig. 11), no se aprecia una relación obvia con NDVI. Los modelos de pH con bajo R<sup>2</sup> puede que se asocian a una menor representatividad respecto de la eventual variación intraparcalaria.

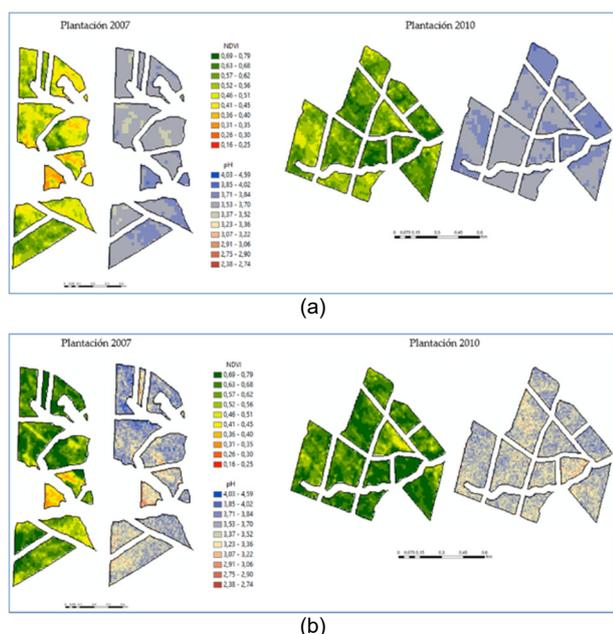


Figura 11: Mapa de modelación de pH para las temporadas: a) 2017; b) 2018.

Tabla 1: Ecuaciones para modelación de °Brix y pH. Temporadas 2017 y 2018.

Temporada	Modelo
Brix 2017	$Brix = 25,784 + 0,0122621*B4 - 0,00706689*B6 + 21,5251*NDMI$
Brix 2018	$Brix = 65,3742 - 0,0290864*B3 + 0,00840046*B8 - 73,7171*GNDVI$
pH 2017	$pH = 2,86924 + 0,000569594*B6 - 0,0000339141*B11 + 0,000296875*B12$
pH 2018	$pH = 1,31306 + 0,000736344*B3 - 0,00594737*B4 - 3,84222*CHLORO$

#### 4. Discusión

Aunque las variables meteorológicas se abordaron en este estudio como un precedente para el área y no como una variable, hubo diferencias de temperatura de hasta 4° en la primera quincena de enero, y la precipitación acumulada se duplicó en comparación con la anterior en la temporada 2018. Trought *et al.* (2008) indican que pequeñas diferencias de temperatura pueden tener influencia en la fenología de la vid. En nuestro caso, el °Brix aumentó ligeramente durante 2018, un año más fresco y con menos radiación. Aunque se espera que una temperatura y una radiación más altas faciliten la acumulación de azúcar, autores como Abeyasinghe *et al.* (2019) encontraron que el crecimiento de la baya fue retrasado por sombras muy densas, pero el índice de acumulación de azúcar no fue afectado. Si tenemos en cuenta estos estudios, sería deseable considerar las condiciones climáticas como una variable adicional que podría mejorar el modelo estimado.

Otros estudios han determinado la importancia de estas condicionantes en antocianinas, recordemos que con el inicio del enero se empiezan a acumular conjuntamente azúcares y antocianinas las cuales están en directa relación (Coombe and Mccarthy 2000). Sin embargo,

como producto de los cambios de temperatura se podría provocar un desfase entre azúcares y antocianinas, así como la alteración de sus vías de acumulación y degradación (Schultz and Jones 2010). Del Valle *et al.* (2005) plantean que la luminosidad la estimula y las altas temperaturas la inhiben. Así mismo, Peña (2009) plantea que el clima de la zona y su efecto térmico y lumínico tiene gran influencia en todo el proceso de desarrollo, afectando el proceso fotosintético y a la formación de azúcares y ácidos. De igual forma lo plantean (Gutiérrez-Gamboa and Moreno-Simunovic 2018), cuando indican que las condiciones climáticas afectan a la maduración de la uva más que las características del suelo.

Las imágenes satelitales cobran real importancia cuando tienen la capacidad de registrar la variabilidad espacial del viñedo, fundamental para tomar decisiones del manejo agronómico (Mashalaba *et al.* 2020). Actualmente, se utilizan sensores electrónicos para detectar variabilidad entre parcelas a fin de permitir la aplicación de un manejo diferenciado en fertilización, poda o cosecha (Llorens *et al.* 2010). En efecto, tal como remarcan Arnó *et al.* (2017), la cosecha diferenciada tiene ventajas económicas para una viticultura más sostenible y competitiva. En este sentido, los resultados de este trabajo muestran la posibilidad de cartografiar la variabilidad espacial de indicadores de calidad de la uva de vinificación, como son los ° Brix y el pH, no sólo entre parcelas sino también intra-parcelas, mediante la obtención de modelos derivados de índices espectrales obtenidos a partir de imágenes Sentinel-2 de gran utilidad para el manejo diferenciado de las cosechas, aportando información espacial para la recolección selectiva con vistas a categorizar diferentes tipos de vino.

#### 5. Conclusiones

El presente trabajo de investigación tiene como fin determinar variaciones intraparceldarias mediante la modelación de dos de los factores fundamentales de calidad de vino: la acumulación de azúcar, medida en grados brix y el pH, a partir de variables extraídas de imágenes Sentinel 2. El trabajo se llevó a cabo en dos temporadas de cosecha y se consideraron cuatro fechas previas a la cosecha. Los mapas generados a partir de los modelos construidos pueden permitir, de forma semiautomática y con alta fiabilidad, dividir las parcelas de cultivo en varias regiones con características homogéneas (°Brix y pH) que podrían recibir un tratamiento diferencial en la cosecha. La incorporación de soluciones tecnológicas, como el uso de imágenes satelitales para el proceso de muestreo de frutas, permite mejorar un proceso artesanal, al generar un mapa de valores predichos de °Brix y pH. Esto permite definir las áreas clave a revisar en el campo, aumentando las posibilidades de llevar a cabo una cosecha dirigida, a través de muestreos específicos del sitio, lo que da la capacidad de tomar decisiones en el manejo del viñedo. En este punto, las imágenes satelitales gratuitas con alta periodicidad son accesibles incluso para viñedos más pequeños, dando la posibilidad de determinar áreas dentro de las parcelas que deben ser estudiadas y eventualmente cosechadas de manera diferenciada, ya que una adecuada selección de uvas con características similares es un factor clave para mejorar la calidad y productividad de la vinificación.

## References

- ABEYSINGHE, S. K., GREER, D. H., and ROGIERS, S. Y., 2019. The effect of light intensity and temperature on berry growth and sugar accumulation in *Vitis vinifera* "Shiraz" under vineyard conditions. *Vitis*, **58**(1), pp. 7–16. DOI: 10.5073/vitis.2019.58.7-16
- AMMONIACI, M., KARTSIOTIS, S., PERRIA, R., and STORCHI, P., 2021. State of the Art of Monitoring Technologies and Data Processing for Precision Viticulture. *MDPI*, **11**(Agriculture). DOI: 10.3390/agriculture11030201
- ARNÓ, J., BORDES, X., RIBES-DASI, M., BLANCO, R., ROSELL, J. R., and ESTEVE, J. 2005. Obtaining grape yield maps and analysis of within-field variability in Raimat (Spain). *Precision Agriculture 2005, ECPA 2005*, June 2015, pp. 899–906.
- ARNÓ, J., MARTÍNEZ CASASNOVAS, J. A., RIBES DASI, M., and ROSELL, J. R., 2009. Review. Precision viticulture. Research topics, challenges and opportunities in site-specific vineyard management. *Spanish Journal of Agricultural Research*, **7**(4). DOI: 10.5424/sjar/2009074-1092
- ARNÓ, JAUME, MARTÍNEZ-CASASNOVAS, J. A., and TEJADA MORAL, M., 2017. Assessing opportunities for selective winery vintage with a market-driven composite index. *Cogent Food & Agriculture*, **3**(1), 1386438. DOI: 10.1080/23311932.2017.1386438
- ATZBERGER, C., 2013. Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs. *Remote Sensing*, **5**(2), 949–981. DOI: 10.3390/rs5020949
- BONILLA, I., DE TODA, F. M., and MARTÍNEZ-CASASNOVAS, J. A., 2015. Vine vigor, yield and grape quality assessment by airborne remote sensing over three years: Analysis of unexpected relationships in cv. Tempranillo. *Spanish Journal of Agricultural Research*, **13**(2), pp. 1–8. DOI: 10.5424/sjar/2015132-7809
- BORGOGNO-MONDINO, E., LESSIO, A., TARRICONE, L., NOVELLO, V., and DE PALMA, L., 2018. A comparison between multispectral aerial and satellite imagery in precision viticulture. *Precision Agriculture*, **19**(2), pp. 195–217. DOI: 10.1007/s11119-017-9510-0
- BRAMLEY, R. G. V., 2010. Precision Viticulture: Managing vineyard variability for improved quality outcomes. In *Managing Wine Quality: Viticulture and Wine Quality*. Woodhead Publishing Limited. DOI: 10.1533/9781845699284.3.445
- BROM, J., NEDBAL, V., PROCHÁZKA, J., and PECHAROVÁ, E., 2012. Changes in vegetation cover, moisture properties and surface temperature of a brown coal dump from 1984 to 2009 using satellite data analysis. *Ecological Engineering*, **43**, pp. 45–52. DOI: 10.1016/j.ecoleng.2011.03.001
- BUZZETTI, C., 2018. Una Mirada al Mercado Vitivinícola Nacional e Internacional. Santiago de Chile, Chile: Odepa.
- CASTRO, A. L., 2005. *Efecto del Momento de Cosecha de Uva cv. Merlot sobre la composición química y sensorial de los vinos en el valle del Maipo*. Universidad de Chile.
- CATANIA, C., and AVAGNINA, S., 2007. La maduración de la uva. *Curso Superior de Degustación de Vinos*, pp. 1–14.
- CHAVES, M. M., HARLEY, P. C., TENHUNEN, J. D., and LANGE, O. L., 1987. Gas exchange studies in two Portuguese grapevine cultivars. *Physiologia Plantarum*, **70**(4), pp. 639–647. DOI: 10.1111/j.1399-3054.1987.tb04318.x
- COOMBE, B. G., and MCCARTHY, M. G., 2000. Dynamics of grape berry growth and physiology of ripening. *Australian Journal of Grape and Wine Research*, pp. 131–135.
- CORTELL, J. M., HALBLEIB, M., GALLAGHER, A. V., RIGHETTI, T. L., and KENNEDY, J. A., 2005. Influence of vine vigor on grape (*Vitis vinifera* L. Cv. Pinot noir) and wine proanthocyanidins. *Journal of Agricultural and Food Chemistry*, **53**(14), 5798–5808. DOI: 10.1021/jf0504770
- CUNHA, M., MARÇAL, A. R. S., and SILVA, L., 2010. Very early prediction of wine yield based on satellite data from vegetation. *International Journal of Remote Sensing*, **31**(12), pp. 3125–3142. DOI: 10.1080/01431160903154382
- DEL VALLE, G.; GONZALEZ, A.; and BAEZ, R., 2005. Antocianinas en uva (*Vitis vinifera* L.) y su relación con el color. *Revista Fitotecnia Mexicana*, **28**(4), pp. 359–368.
- DEVAUX, N., CRESTEY, T., LEROUX, C., and TISSEYRE, B., 2019. Potential of Sentinel-2 satellite images to monitor vine fields grown at a territorial scale. *Oeno One*, **53**(1), pp. 51–58. DOI: 10.20870/oeno-one.2019.53.1.2293
- FORINO, M., PICARIELLO, L., RINALDI, A., MOIO, L., and GAMBUTI, A., 2020. How must pH affects the level of red wine phenols. *Lwt*, **129**(January), 109546. DOI: 10.1016/j.lwt.2020.109546
- GAO, B.-C., 1996. NDWI A Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water From Space. *Elsevier*, **23**(3), pp. 257–266. DOI: 10.1016/j.lwt.2020.109546
- GIRALDO, C., 2017. Escenarios de la Vitivinicultura Chilena generados por los cambios en la aptitud Productiva, como consecuencia del cambio climático para mediados del siglo XX1. In Universidad de Chile, Facultad de Ciencias Forestales y de la Conservación de la Naturaleza (Issue Proyecto de tesis). Universidad de Chile.

- GUTIÉRREZ-GAMBOA, G., and MORENO-SIMUNOVIC, Y., 2018. Location effects on ripening and grape phenolic composition of eight 'carignan' vineyards from maule valley (Chile). *Chilean Journal of Agricultural Research*, **78**(1), pp. 139–149. DOI: 10.4067/S0718-58392018000100139
- HALL, A., LOUIS, J., and LAMB, D., 2003. Characterising and mapping vineyard canopy using high-spatial- resolution aerial multispectral images. *Computers and Geosciences*, **29**(7), pp. 813–822. DOI: 10.1016/S0098-3004(03)00082-7
- HALLIK, L., KAZANTSEV, T., KUUSK, A., GALMÉS, J., TOMÁS, M., and NIINEMETS, Ü., 2017. Generality of relationships between leaf pigment contents and spectral vegetation indices in Mallorca (Spain). *Regional Environmental Change*, **17**(7), pp. 2097–2109. DOI: 10.1007/s10113-017-1202-9
- HERNÁNDEZ, C., ESCRIBANO, J., and TARQUIS, A., 2014. Comparación del Índice de Vegetación de Diferencia Normalizada obtenido a diferentes escalas en pastos de Dehesa. *Pastos y PAC 2014-2020*, pp. 121–128.
- HERRERA, M. E., and CHUVIECO, E., 2014. Estimación del contenido de agua a partir de mediciones hiperespectrales para cartografía del riesgo de incendio. *Cuadernos de Investigación Geografica*, **40**(2), pp. 295–309. DOI: 10.18172/cig.2518
- JOHNSON, L. F., ROCZEN, D. E., YOUKHANA, S. K., NEMANI, R. R., and BOSCH, D. F., 2003. Mapping vineyard leaf area with multispectral satellite imagery. *Computers and Electronics in Agriculture*, **38**(1), pp. 33–44. DOI: 10.1016/S0168-1699(02)00106-0
- KHALIQ, A., COMBA, L., BIGLIA, A., RICAUDA AIMONINO, D., CHIABERGE, M., and GAY, P., 2019. Comparison of satellite and UAV-based multispectral imagery for vineyard variability assessment. *Remote Sensing*, **11**(4). DOI: 10.3390/rs11040436
- LIMA, L.J., 2015. Estudio De Caracterización De La Cadena De Producción Y Comercialización De La Agroindustria Vitivinícola: Estructura, Agentes Y Prácticas. Oficina de Estudios y Políticas Agrarias. *Ministerio de Agricultura*, **208**.
- LIU, Y., YANG, P., YUAN, C., WANG, H., HAN, F., LIU, Y., and WANG, L., 2018. Stability of anthocyanins and their degradation products from cabernet sauvignon red wine under gastrointestinal pH and temperature conditions. *Molecules*, **23**(2). DOI: 10.3390/molecules23020354
- LLORENS, J., GIL, E., LLOP, J., and ESCOLÀ, A., 2010. Variable rate dosing in precision viticulture: Use of electronic devices to improve application efficiency. *Crop Protection*, **29**(3), pp. 239–248. DOI: /10.1016/j.cropro.2009.12.022
- MARTINEZ-CASASNOVAS, J. A., AGELET, J., ARNÓ, J., BORDES, X., and RAMOS, M. C., 2010. Protocolo para la Zonificación Intraparcelaria de la Viña para Vendimia Selectiva a partir de Imágenes Multiespectrales. *Revista de Teledetección*, pp. 47–52.
- MARTINEZ-CASASNOVAS, J. A., AGELET-FERNANDEZ, J., ARNO, J., and RAMOS, M. C., 2012. Análisis de zonas de manejo diferencial en viñedo y relación con el desarrollo de la viña, madurez y calidad de la uva. *Spanish Journal of Agricultural Research*, **10**(2), pp. 326–337. DOI: 10.5424/sjar/2012102-370-11
- MASHALABA, L., GALLEGUILLOS, M., SEGUEL, O., and POBLETE-OLIVARES, J., 2020. Predicting spatial variability of selected soil properties using digital soil mapping in a rainfed vineyard of central Chile. *Geoderma Regional*, **22**, e00289. DOI: 10.1016/j.geodrs.2020.e00289
- MATESE, A., and DI GENNARO, S. F., 2015. Technology in precision viticulture: A state of the art review. *International Journal of Wine Research*, **7**(1), pp. 69–81. DOI: 10.2147/IJWR.S69405
- MÜLLER, K., 2004. Chile vitivinícola en pocas palabras. *Revista de Enología*, **52**.
- PARDO, J. A., 2016. Seguimiento Fenológico del Cultivo de Uva Isabela (*Vitis* sp) en Fusagasuga Cundinamarca. Universidad de Cundinamarca.
- PASTONCHI, L., DI GENNARO, S. F., TOSCANO, P., and MATESE, A., 2020. Comparison between satellite and ground data with UAV-based information to analyse vineyard spatio-temporal variability. *Oeno One*, **54**(4), pp. 919–934. DOI: 10.20870/OENO-ONE.2020.54.4.4028
- PEÑA, A., 2005. Factores que regulan el color en uvas tintas. Pp. 12–14.
- PEÑA, A., 2009. Cambios composicionales de la baya durante el proceso de maduración y su importancia en la calidad de la uva y el vino. Grupo de Investigación Enológica (GIE). Universidad de Chile.
- PEREZ QUEZADA, J., 2006. Viticultura de Precisión Aplicada Al Viñedo. *Revista Enología N°2*. Facultad de Ciencias Agronómicas Universidad de Chile, pp. 1–3.
- PICARIELLO, L., RINALDI, A., FORINO, M., PETRACCA, F., MOIO, L., and GAMBUTI, A., 2019. Modification of the organic acid profile of grapes due to climate changes alters the stability of red wine phenolics during controlled oxidation. *Vitis - Journal of Grapevine Research*, **58**(127), pp. 127–133. DOI: 10.5073/vitis.2019.58.special-issue.127-133
- PRIORI, S., PELLEGRINI, S., PERRIA, R., PUCCIONI, S., STORCHI, P., VALBOA, G., and COSTANTINI, E. A. C., 2019. Scale effect of terroir under three contrasting vintages in the Chianti Classico area (Tuscany, Italy). *Geoderma*, **334**(July 2018), pp. 99–112. DOI: 10.1016/j.geoderma.2018.07.048

- REYNOLDS, A. G., and REZAEI, J. H., 2014. Spatial variability in Ontario Cabernet franc vineyards III. Relationships among berry composition variables and soil and vine water status. *Journal of Applied Horticulture*, **16**(3), pp. 167–192. DOI: 10.37855/jah.2014.v16i03.30
- SCHULTZ, H. R., and JONES, G. V., 2010. Climate induced historic and future changes in viticulture. *Journal of Wine Research*, **21**(2), pp. 137–145. DOI: 10.1080/09571264.2010.530098
- SOZZI, M., KAYAD, A., MARINELLO, F., TAYLOR, J. A., and TISSEYRE, B., 2020. Comparing vineyard imagery acquired from sentinel-2 and unmanned aerial vehicle (UAV) platform. *Oeno One*, **54**(2), pp. 189–197. DOI: 10.20870/oeno-one.2020.54.2.2557
- SUN, L., GAO, F., ANDERSON, M. C., KUSTAS, W. P., ALSINA, M. M., SANCHEZ, L., SAMS, B., MCKEE, L., DULANEY, W., WHITE, W. A., ALFIERI, J. G., PRUEGER, J. H., MELTON, F., and POST, K., 2017. Daily mapping of 30 m LAI and NDVI for grape yield prediction in California vineyards. *Remote Sensing*, **9**(4), pp. 1–18. DOI: 10.3390/rs9040317
- TAYLOR, J., TISSEYRE, B., BRAMLEY, R., and REID, A., 2005. A comparison of the spatial variability of vineyard yield in European and Australian production systems. *Precision Agriculture 2005, ECPA 2005, October 2015*, pp. 907–914.
- TROUGHT, M. C. T., DIXON, R., MILLS, T., GREVEN, M., AGNEW, R., MAUK, J. L., and PRAAT, J. P., 2008. The impact of differences in soil texture within a vineyard on vine vigour, vine earliness and juice composition. *Journal International Des Sciences de La Vigne et Du Vin*, **42**(2), pp. 62–72. DOI: 10.20870/oeno-one.2008.42.2.828
- URIBE, H., and CATALAN, A., 2016. Caracterización hidroclimatológica y del uso de suelo del secano de la región de O'higgins. *Boletín Inia N°320*, ISSN0717-4, pp. 49–81.
- URRETAVIZCAYA, I., SANTESTEBAN, L. G., TISSEYRE, B., GUILLAUME, S., MIRANDA, C., and ROYO, J. B., 2013. Oenological significance of vineyard management zones delineated using early grape sampling (Precision Agric, 10.1007/s11119-013-9328-3). *Precision Agriculture*, **15**(1), pp. 130–131. DOI: 10.1007/s11119-013-9328-3
- VAN LEEUWEN, C., FRIANT, P., CHONÉ, X., TREGOAT, O., KOUNDOURAS, S., and DUBOURDIEU, D., 2004. Influence of climate, soil, and cultivar on terroir. *American Journal of Enology and Viticulture*, **55**(3), pp. 207–217.
- WANG, L., HUNT, E. R., QU, J. J., HAO, X., and DAUGHTRY, C. S. T., 2013. Remote sensing of fuel moisture content from ratios of narrow-band vegetation water and dry-matter indices. *Remote Sensing of Environment*, **129**, pp. 103–110. DOI: 10.1016/j.rse.2012.10.027
- WANG, L., QU, J. J., HAO, X., and HUNT, E. R., 2011. Estimating dry matter content from spectral reflectance for green leaves of different species. *International Journal of Remote Sensing*, **32**(22), pp. 7097–7109. DOI: 10.1080/01431161.2010.494641