

A Digital Platform for the Management of Grapes and Wine Quality in the Winery

Ricardo Luna*, Mauricio Araya†, José Caris‡ and José Cuevas-Valenzuela§

Centro de Investigación e Innovación, Viña Concha y Toro
Pencahue, Chile

Email: *ricardo.luna@conchaytoro.cl, †mauricio.araya@conchaytoro.cl, ‡jose.caris@conchaytoro.cl, §jose.cuevas@conchaytoro.cl

Abstract—The management of industrial winemaking is a complex challenge since there is a lot of uncertainty from the vineyard to the winery. In particular, climate change has had a negative effect on the management of harvest dates and the winery's capacity. Digital tools like the Industrial Internet of things (IIoT) allow integrating the productive processes data and used it for decision-making. In addition, model-based design such as the machine learning approach and first-principle models can generate a computational tool to optimize the fermentation process's management. In this work, we developed a digital platform to manage grapes and wine quality in the winery. We defined, adapted, and implemented an infrastructure of IIoT to use the digital platform in the winery successfully. Finally, we validated the digital platform and the infrastructure of IIoT in a test pilot of the industrial scale during the 2020 harvest season.

Keywords—winemaking, tannins, anthocyanins, internet of things, modeling, machine learning

I. INTRODUCCIÓN

El cambio climático y el calentamiento global han tenido un impacto en la fenología de los cultivos afectando la calidad de las uvas. Las altas temperaturas han generado cambios en la composición química de la uva y en las propiedades del mosto. Lo anterior, se ve reflejado en una compresión del periodo de cosecha de la uva, es decir, la uva se está cosechando de forma más adelantada en comparación con los periodos de cosechas obtenidos en los años anteriores [1].

En la industria, existe evidencia que los periodos comprimidos de cosechas conducen a problemas en la gestión y logística de esta, afectando a la programación de camiones y entrada de la uva a una determinada bodega. Consecutivamente, la planificación, gestión y productividad de una bodega también se ve alterada. En particular, la gestión de la bodega está restringida a la capacidad y disponibilidad de estanques de fermentación en una fecha determinada. En consecuencia, los enólogos en muchas ocasiones deben tomar decisiones *in situ* durante el manejo de la fermentación alcohólica, con el objetivo de realizar un proceso eficiente que mantenga calidad o tipicidad de los vinos producidos.

Para el caso del vino tinto, la calidad está definida por atributos como el color, sensación en boca, amargor, astringencia, entre otros [2]. Las antocianinas y los pigmentos poliméricos son responsables del color del vino, mientras que los taninos son responsables del amargor, sensación en boca y la astringencia del vino [3–5]. Estos compuestos son extraídos desde la piel y semillas de las uvas, donde el mosto es fermentado en contacto con el orujo y las semillas. Este proceso es conocido como maceración o maceración fermentativa. En general, este proceso puede durar entre cinco a ocho días dependiendo de variables como la temperatura de fermentación y el tiempo de contacto entre el mosto y los sólidos. Por lo tanto, una gestión óptima de los tiempos de maceración fermentativa puede mejorar la capacidad y productividad de una bodega, y disminuir los costos de producción manteniendo la calidad del producto.

En este contexto, el generar una tecnología que permita gestionar la calidad del vino de forma óptima es una necesidad global en la industria del vino. Para ello es necesario contar con funcionalidades como el monitoreo mediante sensores, así como el control, predicción y optimización del proceso de vinificación. Aquí, las tecnologías digitales como el internet industrial de las cosas (IIoT, por su sigla en inglés) permiten integrar la información de los diferentes sensores en los procesos productivos, y usar esta información en la toma de decisiones [6]. De esta forma se genera valor para el negocio (*business value*) de forma continua, en un proceso cíclico de información entre el mundo físico y digital [7]. Además, el diseño basado en modelos (*model-based design*) pueden generar una herramienta computacional mediante la predicción y optimización de las variables que definen la calidad de los vinos. Este enfoque permite diseñar estrategias de procesos complejos de forma rápida y confiable en comparación con ensayos experimentales de prueba y error [8,9]. Por lo tanto, el uso de modelos de primeros principios, modelos basados en *machine learning* y algoritmos de optimización son herramientas claves que pueden entregar como resultado una prescripción que sea aplicada al proceso de vinificación durante el periodo de vendimia.

En este trabajo, presentamos los resultados asociados al desarrollo e implementación de una plataforma digital

para la gestión de la calidad de uvas y vinos (PDGCUV) en bodega, la que integra cada una de las tecnologías descritas anteriormente. La plataforma está compuesta por cuatro módulos que incluyen: i) monitoreo en tiempo real de un estanque de fermentación, ii) predicción del proceso de vinificación compuesto por un modelo de cinética de fermentación y modelos *machine learning*, iii) prescripción de acciones enológicas basada en información del proceso y la optimización de los modelos, y iv) diagnóstico basado en los datos históricos de los procesos de vinificación ejecutados en una bodega. El desarrollo de la PDGCUV implicó definir, adaptar e implementar una infraestructura IIoT adecuada para su uso en bodegas. Tanto la PDGCUV como la infraestructura IIoT fueron implementadas en productivo y validadas en un piloto de prueba en bodega industrial Lourdes (Región del Maule, Chile) de Viña Concha y Toro utilizando uvas Cabernet Sauvignon (CS) durante el periodo de vendimia 2020.

II. DESARROLLO DE LA PLATAFORMA DIGITAL

La infraestructura IIoT desarrollada es una adaptación de los estándares descritos en la literatura técnica [10–12] y comprende siete niveles (Fig. 1).

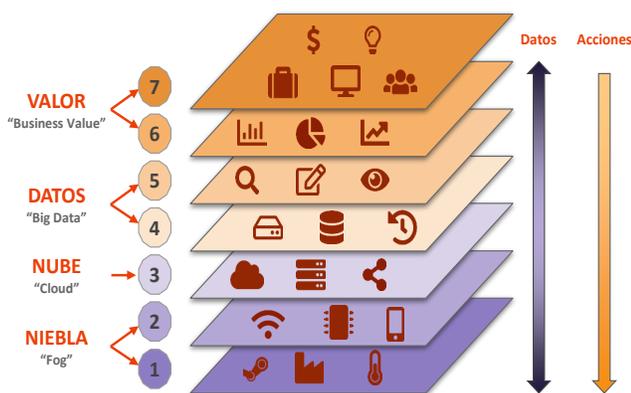


Fig. 1. Infraestructura IIoT implementada en la bodega industrial de Lourdes para la aplicación de la plataforma de gestión de calidad de uvas y vinos (PDGCUV).

El primer nivel incluye las mediciones de los sensores, actuadores y controladores que están instalados en los estanques de fermentación (*fog computing*). Aquí, la información de estos componentes fue obtenida mediante *Open Protocol Communication* (OPC). Consecutivamente, el nivel *cloud* comprende una infraestructura global de servidores como un DataCenter de Viña Concha y Toro (11 GB memoria Ram, 5 núcleos Intel® Xeon CPU E5-2697 v4 2.30GHz), un servidor HP proliant (Intel Core I5 CPU 2.50GHz, 8 GB memoria Ram) y un Workstation HP Z6 (32 GB de Ram, 20 procesadores, Intel® Xeon® 3.30 GHz) instalados en el Centro de Investigación e Innovación (CII) de Viña Concha y Toro. En este nivel, es donde los servidores

almacenan grandes volúmenes de datos y son dispuestos para poder ser utilizados en los siguientes niveles. El nivel del *big data* está compuesto por herramientas computacionales como análisis estadísticos e inteligencia artificial. En esta capa es donde fueron desarrollados los diferentes modelos predictivos con los que cuenta la PDGCUV. Estos modelos utilizaron la información histórica almacenada y fueron entrenados mediante algoritmos de optimización y *machine learning*. Finalmente, el nivel de *business value* genera información de valor para la toma de decisiones mediante el consumo automático de datos y procesamiento de información en los niveles previos. En este nivel, es donde se encuentra la plataforma PDGCUV y todas sus aplicaciones disponibles para los usuarios finales, fundamentalmente enólogos.

Para el desarrollo mismo de la plataforma PDGCUV se instalaron y configuraron diferentes servicios y herramientas haciendo uso de software *open-source* en el servidor Workstation. Como servidor web se utilizó Apache v.2.4.18 que permitió el funcionamiento de la plataforma mediante la interpretación de los diferentes lenguajes que se utilizaron para su desarrollo (php, Javascript, html, CSS, JSON, entre otros). La ejecución e integración de las funcionalidades como monitoreo y predicción de la plataforma se llevaron a cabo mediante el desarrollo de un servicio informático que le hemos llamado *WebServices Machine Learning Python*. Este servicio permitió el intercambio del flujo de datos entre la predicción de los modelos y los datos almacenados en la PDGCUV mediante diferentes librerías de Python como *cherry.py*, *pickle*, *pandas*, entre otras. Además, se utilizó PostgreSQL v9.5.19 para generar un servicio optimizado de base de datos. Esta herramienta permitió el almacenamiento de diferentes fuentes de información como lo son los datos operacionales de la fermentación en bodega y los resultados de los análisis químicos obtenidos en el laboratorio. Las funcionalidades de la plataforma PDGCUV se resumen, como se describió previamente, en cuatro módulos: Monitoreo, Diagnóstico, Predicción y Prescripción.

A. Monitoreo

El módulo de monitoreo permite visualizar en línea las variables de operación durante una fermentación alcohólica. Para ello se integraron los datos de sensores de temperatura mediante un servicio instalado y configurado en el Workstation llamado ODBC (*Open Data Base Connectivity*). La información de los sensores de densidad fue integrada a través de servicios API. El Workstation realizó un muestreo de la información de los sensores cada un minuto para luego ser recopiladas por la plataforma digital. En total se integró la información de sensores de nueve estanques de fermentación de capacidad de 100 hL.

B. Diagnóstico

El módulo de diagnóstico muestra la información histórica del proceso de vinificación de la bodega por cada periodo de vendimia. Para ello, se realizó una estadística descriptiva a

diferentes variables de interés para los enólogos durante la elaboración de vinos: datos químicos de la uva como acidez total, pH, y grados brix, composición fenólica en la uva y en el vino al final de la maceración.

C. Predicción

El módulo de predicción está compuesto por dos unidades de predicción: índice de calidad de los vinos Cabernet Sauvignon y un simulador de vinificación.

Índice de calidad

Para la predicción del índice de calidad (IC) se desarrollaron modelos basados en machine learning a partir de datos químicos obtenidos de uva (CS) y datos sensoriales que fueron obtenidos mediante un panel sensorial de expertos (Fig. 2).



Fig. 2. Esquema general para la construcción del modelo de índice de calidad de vinos CS.

La base de datos se construyó a partir de la uva CS cosechada y los vinos obtenidos de estas en los periodos de vendimia 2018 y 2019. En total se obtuvo información química y sensorial de 100 muestras. Los marcadores químicos fueron densidades ópticas a 280, 420, 520 y 620 nm, taninos y antocianinas totales los cuales fueron obtenidos mediante espectrofotometría UV-vis. El análisis sensorial de los vinos fue dividido en 50 vinos de aptitud varietal y 50 de aptitud premium. Para los vinos varietales se evaluó calidad aromática, calidad en boca y calidad global, mientras que para vinos premium se dividió el atributo calidad en boca en suavidad y grasa. Todos los atributos fueron medidos en una escala del 1 al 9. Se utilizaron algoritmos de regresión basados en machine learning para la predicción de cada atributo sensorial como *gradient Boosting Regressor* [13] y *linear support vector regression* (SVR) [14]. Además, para cada aptitud de vino (varietal y premium) los vinos fueron divididos en tres categorías A, B y C (alta, media y baja calidad) por los enólogos. Para predecir la categoría de calidad se utilizó un modelo de clasificación basado en redes neuronales utilizando la librería *TensorFlow* [15].

Simulador de vinificación

El simulador de vinificación está compuesto por dos modelos que predicen la cinética de fermentación y la concentración

de compuestos fenólicos como taninos y antocianinas al final de la maceración fermentativa (al descube).

i) Cinética de fermentación

El modelo de cinética de fermentación (CN) se basa en primeros principios como lo son la conservación de masa y energía. El modelo corresponde a un set de ecuaciones diferenciales y algebraicas dependientes del tiempo de la forma:

$$\begin{aligned} \frac{dx}{dt} &= f(x(t), u(t), \theta) \\ y(t) &= h(x(t), \theta) \end{aligned} \quad (1)$$

donde x , y , u y θ corresponden a los vectores de variables de estado, variables algebraicas observadas, entradas del modelo y parámetros del modelo, respectivamente. Las variables que predice el modelo son el consumo de azúcar y nutrientes, generación de alcohol y la densidad del mosto/vino durante el proceso de fermentación. El detalle de las ecuaciones del modelo se encuentra reportado en [16]. Los parámetros del modelo fueron recalibrados con vinificaciones experimentales en un bioreactor de 5 L utilizando uva CS 2019. El modelo fue implementado en la plataforma PDGCUV mediante el uso de las librerías *numpy*, *scipy* de Python.

ii) Predicción de taninos y antocianinas

Estos modelos fueron construidos a partir de datos históricos de procesos de vinificación utilizando técnicas de aprendizaje automático (*machine learning*). Para ello, se generó una base de datos con información de 97 procesos de vinificación utilizando uva CS durante los periodos de vendimia 2017, 2018 y 2019. Los procesos de vinificación fueron obtenidos de siete bodegas de Viña Concha y Toro con uvas provenientes de cinco diferentes valles a lo largo de Chile. Durante el proceso de vinificación fueron definidos cuatro puntos de muestreo (Fig. 3a).

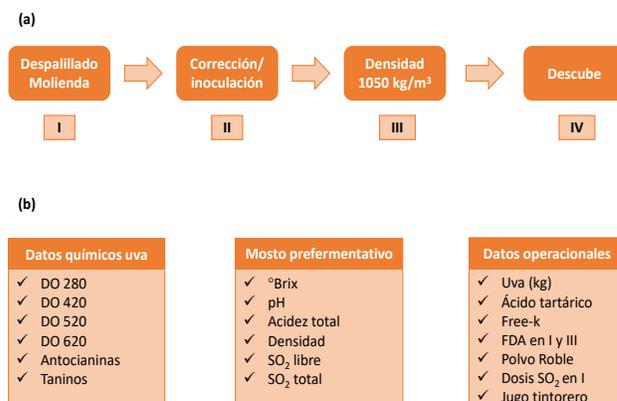


Fig. 3. (a) Puntos de muestreo para el seguimiento de los procesos de vinificación de CS. (b) Variables medidas y usadas para la construcción de los modelos de predicción de taninos y antocianinas.

IV. RESULTADOS

A. Módulos plataforma PDGCUV

Los resultados de los análisis químicos realizados a todas las muestras (uva, mosto y vino CS) durante el periodo vendimia 2020 se observaron mediante el módulo de diagnóstico (Fig. 5).

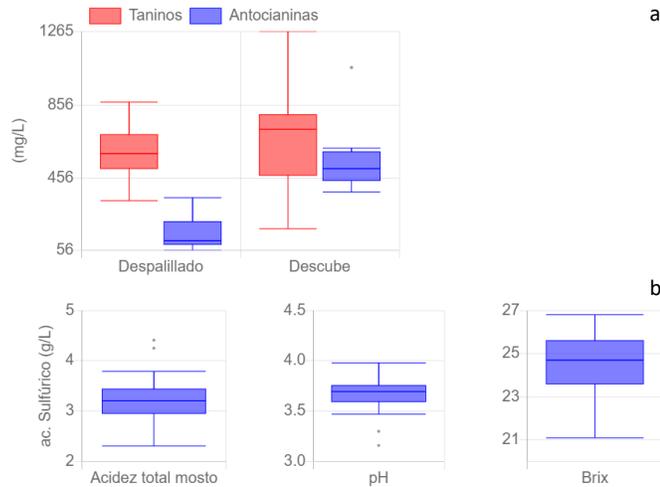


Fig. 5. Módulo de diagnóstico: gráficos boxplot para las variables medidas en uva, mosto y vino CS durante vendimia 2020.

Los resultados fueron mostrados en gráficos boxplot con el objetivo de tener la información de la estadística descriptiva de forma visual para el enólogo (usuario). Esta información le permite continuamente al enólogo tener un conocimiento histórico por cada temporada de vendimia sobre las uvas que reciben en la bodega y consecutivamente los vinos que son producidos en ella. La Figura 5a muestra la información fenólica (taninos y antocianinas) de la uva antes de la fermentación y del vino obtenido al final de la fermentación. La Figura 5b muestra los análisis rutinarios que fueron realizados a la uva cuando ingresó en la bodega como acidez total, pH y brix.

La Figura 6 muestra los resultados de la predicción del modelo IC para un determinado proceso de vinificación, el cual hemos designado como “El Boldo-12”. Los resultados del modelo IC indicaron que el vino que se obtendrá de ese proceso de vinificación obtendrá una clasificación B, es decir, una clasificación media dentro de la aptitud premium. Además, el modelo de IC predice la evaluación de los atributos de calidad aromática, calidad global, grasa, suavidad-sequedad donde los valores de todos los atributos fueron prácticamente intermedios entre la escala 1-9. Los resultados del simulador de vinificación fueron validados experimentalmente y se muestran en la sección IV-B.

La fermentación del proceso El Boldo-12 fue visualizada mediante el módulo de monitoreo (Fig. 7). En este módulo se muestra en línea las mediciones como la temperatura del

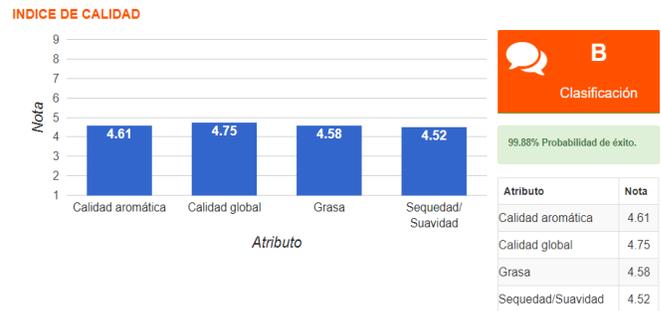


Fig. 6. Módulo de predicción: resultados modelo IC.

proceso, set-point de temperatura y la densidad del mosto que indica el grado de avance de la fermentación.

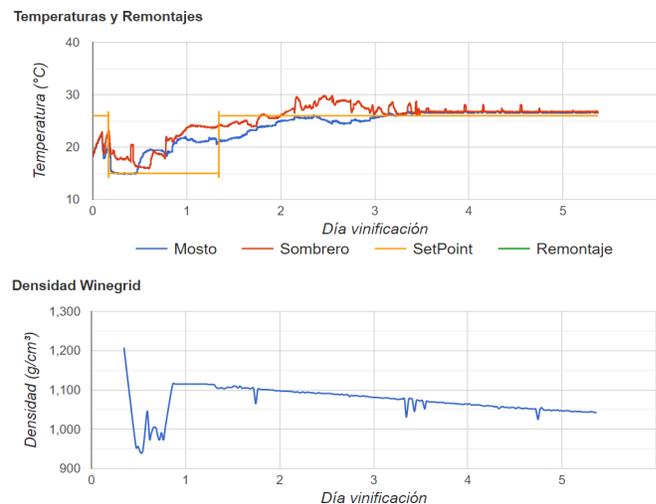


Fig. 7. Módulo de monitoreo: seguimiento del proceso de fermentación del ensayo El Boldo-12.

El módulo de prescripción entregó como resultado un conjunto de 100 posibles recetas de vinificación que se podrían ejecutar para el ensayo El Boldo-12 (Fig. 8). El diseño de estas recetas fueron determinadas a partir de los criterios de productividad y calidad definidos en la formulación del problema de optimización multi-objetivo (2).

En la Figura 8, cada círculo azul corresponde a un resultado de receta de vinificación situado en un espacio de tres dimensiones, que corresponden a los objetivos establecidos en el diseño. Con el objetivo de filtrar estos resultados para el enólogo (usuario) en la toma de decisiones, se utilizaron siete algoritmos *multi-criteria decision making*, los cuales permiten seleccionar una alternativa de todo el conjunto de soluciones [19]. Estos algoritmos seleccionaron dos candidatos a recetas de vinificación marcadas con un triángulo rojo y amarillo en la Figura 8. Las recetas seleccionadas destacaron por tener bajos tiempos de maceración con una mayor extracción de

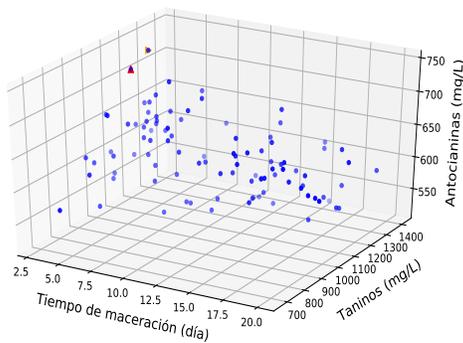


Fig. 8. Módulo de prescripción: recetas de vinificación sugeridas a partir de los criterios de calidad (taninos y antocianinas) y productividad.

taninos y antocianinas, el objetivo que buscan los enólogos en una bodega industrial. La prescripción de estas recetas de vinificación, es decir, las variables de decisión para poder llevarlas a cabo se muestran en la Tabla I.

TABLA I
RECETAS DE VINIFICACIÓN SELECCIONADAS SEGÚN EL MÓDULO DE PRESCRIPCIÓN.

| Variabes | Receta 1 | Receta 2 |
|---------------------------------------|----------|----------|
| Free-k(L) | 68.6 | 1584 |
| FDA I (g/hL) | 40.7 | 34.7 |
| FDA II (g/hL) | 27.1 | 28.3 |
| Polvo roble (g/L) | 0.868 | 1.28 |
| Ácido tartárico (g/L) | 3.28 | 1.60 |
| Sulfuroso (g/hL) | 4.06 | 10.6 |
| Densidad descube (kg/m ³) | 1040 | 1028 |
| Tiempo descube (día) | 3.28 | 4.51 |
| Temperatura promedio (°C) | 23.0 | 20.1 |

B. Validación del simulador de vinificación

Las predicciones del simulador de vinificación, es decir, el modelo CN y AT fueron validadas con dos y cinco ensayos de vinificación a escala industrial en vendimia 2020, respectivamente. Los ensayos corresponden a uva CS proveniente del fundo El Boldo de diferentes cuarteles (Tabla II).

TABLA II
ENSAYOS DE VINIFICACIÓN DE VALIDACIÓN INDUSTRIAL EN VENDIMIA 2020.

| Ensayo | Cuartel | Uva (kg) |
|-------------|------------------------------|----------|
| El Boldo-11 | 80 (50%) y 81(50%) | 84042 |
| El Boldo-12 | 68 (76%), 82 (17%) y 72 (7%) | 102031 |
| El Boldo-16 | 16 (100%) | 79130 |
| El Boldo-18 | 16 (88%) y 1 (12%) | 81070 |
| El Boldo-19 | 88 (100%) | 79852 |

La Figura 9 muestra los resultados de la predicción de la densidad por el modelo CN y la densidad medida por el sensor para los ensayos El Boldo-16 y El Boldo-18. En ambos

ensayos se observa que en general el modelo subestima la densidad medida por el sensor a lo largo de todo el proceso. Sin embargo, la diferencia de unidades de densidad no fue alta, y en el periodo final de la fermentación las predicciones fueron más confiables. En particular, esta zona es la de mayor interés para esta aplicación, dado que se utiliza como herramienta de gestión al descube de la fermentación. Por lo tanto, la predicción de la densidad hacia el final de la fermentación es clave como herramienta predictiva y prescriptiva dentro de la plataforma.

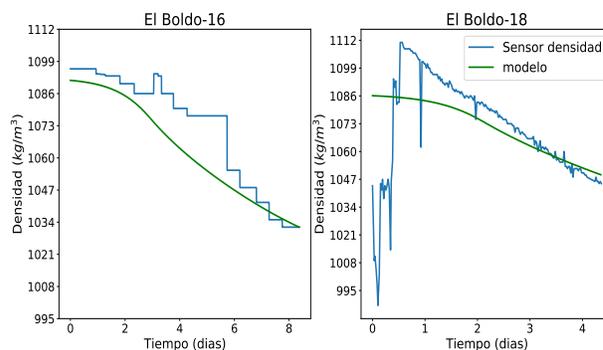


Fig. 9. Validación del modelo CN para dos ensayos CS a escala industrial. Predicción de la cinética de fermentación mediante la medición de densidad.

La Figura 10 muestra la comparación entre la predicción del modelo TA con los resultados obtenidos experimentalmente en el laboratorio. Para el caso del modelo de predicción de taninos, la predicción generalmente sobreestimó el valor experimental a excepción del ensayo El Boldo-12. El error medio porcentual de todos estos ensayos fue de un 22.2% con una desviación estándar de 15%. El modelo de predicción de antocianinas subestimó el valor experimental a excepción del ensayo El Boldo-11. Para este caso el error medio porcentual de todos los ensayos fue de un 12.5% con una desviación estándar de 8.3%. El mejor caso evaluado por ambos modelos fue el ensayo El Boldo-19 obteniendo un error del 3% y 0.8% para el modelo de taninos y antocianinas, respectivamente. Cabe destacar que estos modelos fueron construidos con una base de datos de los periodos de vendimia 2017, 2018 y 2019 y validados con la vendimia 2020. De esta forma, se espera que para los siguientes años con una base de datos más grande la exactitud de estos modelos esté bajo el 10% y que sean más precisos, es decir, que tengan una menor desviación estándar.

V. CONCLUSIÓN

Se ha desarrollado una metodología e infraestructura IIoT que es adecuada para la transformación digital de los procesos enológicos. Primero, se ha conectado información del proceso de fermentación desde una bodega industrial mediante sensores de temperatura, densidad y actuadores (válvulas) al mundo digital (*cloud*). Segundo, la infraestructura IIoT

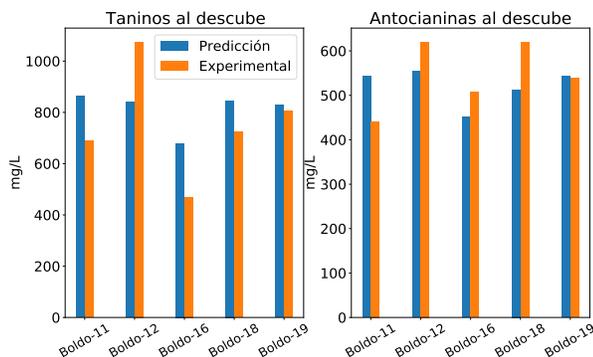


Fig. 10. Validación del modelo TA para cinco ensayos CS a escala industrial.

permitted implementing and validating as a result of R+D different predictive models that have been developed for the digital platform. In addition, it has been possible to generate a tool that allows optimizing the management of the maceration-fermentation process in red wine CS through multi-objective optimization in the prescription module. The results of the models showed an acceptable performance to be in their first pilot test in production. In this way, the PDGCUV platform generated information of value through indicators and graphical tools. Thirdly, the IIoT agnostic infrastructure, that is, that does not have a preference for a specific technology. For this reason, the digital platform allows incorporating existing sensors in the market, new sensors or prototypes, and also technologies with new communication and connectivity systems. This allows implementing or integrating different types of digital tools in a flexible way, so as to develop a platform made to measure. Finally, the development and implementation of the PDGCUV platform was carried out through an agile and methodical methodology. This allowed creating different prototypes, obtaining a constant retro-alignment with the final user who are the enologists. For this reason, the PDGCUV and all its applications will be in constant improvement for use in the next 2021 harvest.

AGRADECIMIENTOS

We thank CORFO for its support through Project 17PIDE-80701. In addition, we thank the enology teams of the different wineries of Viña Concha y Toro, the chemical laboratory team of CII and internal students who have collaborated in the development of this project.

REFERENCIAS

[1] L. B. Webb, P. H. Whetton, and E. W. Barlow, "Modelled impact of future climate change on the phenology of winegrapes in Australia," *Australian Journal of Grape and Wine Research*, vol. 13, no. 3, pp. 165–175, 2007.

[2] L. F. Casassa and J. F. Harbertson, "Extraction, Evolution, and Sensory Impact of Phenolic Compounds During Red Wine Maceration," *Annual Review of Food Science and Technology*, vol. 5, no. 1, pp. 83–109, 2014.

[3] L. Lerno, M. Reichwage, S. Panprivech, R. Ponangi, L. Hearne, A. Oberholster, and D. E. Block, "Chemical gradients in pilot-scale cabernet sauvignon fermentations and their effect on phenolic extraction," *American Journal of Enology and Viticulture*, vol. 68, no. 4, pp. 401–411, 2017.

[4] V. Cheynier, E. Salas, J.-m. Souquet, P. Sarni-manchado, and H. Fulcrand, "Structure and Properties of Wine Pigments and Tannins," *American Journal of Enology and Viticulture*, vol. 57, no. 3, pp. 298–305, 2006.

[5] S. Vidal, L. Francis, S. Guyot, N. Marnet, M. Kwiatkowski, R. Gawel, V. Cheynier, and E. J. Waters, "The mouth-feel properties of grape and apple proanthocyanidins in a wine-like medium," *Journal of the Science of Food and Agriculture*, vol. 83, no. 6, pp. 564–573, 2003.

[6] A. Karmarkar and M. Buchheit, "The Industrial Internet of Things Volume G8: Vocabulary," Industrial Internet Consortium, Tech. Rep., 2018. [Online]. Available: https://www.iiconsortium.org/pdf/IIC_Vocab_Technical_Report_2.1.pdf

[7] V. Ruthers and B. Sniderman, "Around the physical-digital-physical loop: A look at current Industry 4.0 capabilities," Tech. Rep., 2018. [Online]. Available: <https://www2.deloitte.com/us/en/insights/focus/industry-4-0/challenges-on-path-to-digital-transformation/physical-digital-physical-loop.html>

[8] R. Luna, P. Matias-Guiu, F. López, and J. R. Pérez-Correa, "Quality aroma improvement of Muscat wine spirits: A new approach using first-principles model-based design and multi-objective dynamic optimisation through multi-variable analysis techniques," *Food and Bioprocess Technology*, vol. 115, pp. 208–222, 2019.

[9] J. Sacher, L. García-Llobodanin, F. López, H. Segura, and J. R. Pérez-Correa, "The Spirit World: Can chemical engineering help spirits distillers close the loop between historic roots and modern modelling methods?" *The Chemical Engineer*, no. 910, pp. 32–35, 2017.

[10] PMMI, "How to Utilize Bid Data to Enhance Manufacturing Processes," The Association for Packaging and Processing Technologies, Inc., Tech. Rep., 2018.

[11] M. Boland, "IoT Architecture and Design Patterns," 2017.

[12] Cisco, "Reference Model: Building the Internet of the Things," p. 22, 2014.

[13] P. A. Regalia, "Gradient Descent Algorithms," in *Adaptive IIR Filtering in Signal Processing and Control*, New York, 1995, ch. 7, p. 116.

[14] A. J. Smola and B. Scholkopf, "A tutorial on support vector regression," *Statistics and Computing*, vol. 14, pp. 199–222, 2004. [Online]. Available: <https://doi.org/10.1023/B:STCO.0000035301.49549.88>

[15] S. Pattanayak, *Introduction to Deep-Learning Concepts and TensorFlow*. Berkeley, CA: Apress, 2017, pp. 89–152. [Online]. Available: https://doi.org/10.1007/978-1-4842-3096-1_2

[16] M. I. Zenteno, J. R. Pérez-Correa, C. A. Gelmi, and E. Agosin, "Modeling temperature gradients in wine fermentation tanks," *Journal of Food Engineering*, vol. 99, no. 1, pp. 40–48, 2010. [Online]. Available: <http://dx.doi.org/10.1016/j.jfoodeng.2010.01.033>

[17] L. Breiman, "Random Forest," *Machine Learning*, vol. 45, pp. 5–32, 2001.

[18] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, 2002.

[19] Z. Wang and G. P. Rangaiah, "Application and Analysis of Methods for Selecting an Optimal Solution from the Pareto-Optimal Front obtained by Multiobjective Optimization," *Industrial and Engineering Chemistry Research*, vol. 56, no. 2, pp. 560–574, 2017.