

**UNIVERSIDAD DE LA REPÚBLICA
FACULTAD DE AGRONOMÍA**

**EVALUACIÓN DE LA CURVA DE APRENDIZAJE EN
OPERADORES DE HARVESTER PARA COSECHA FORESTAL
MECANIZADA**

por

Gonzalo GARCÍA FREIRE

TESIS presentada como uno de los
requisitos para obtener el título de
Magister en Ciencias Agrarias
Opción Ciencias Vegetales

**MONTEVIDEO
URUGUAY
noviembre 2018**

PÁGINA DE APROBACIÓN

Tesis aprobada por el tribunal integrado por Ing. For. PhD Oscar Vallejos, Ing Agr. PhD Alejandro Olivera e Ing. For. PhD Mauricio Ponce el día 27 de diciembre de 2018. Autor: Ing. Agr. Gonzalo García. Director Ing. Agr. PhD Gustavo Daniluk, Co-directora Ing. Agr. PhD María Virginia Gravina.

AGRADECIMIENTOS

A mi Familia

Ing. Agr. PhD. Gustavo Daniluk

Ing. Agr. PhD. Maria Virginia Gravina

Ing. Agr. MSc. Luis Bentancor

Ing. Agr. PhD. Alejandro Olivera

Ing. Agr. Ney Costa

Ing. Agr. Juan Bide

Ing. Agr. Pablo Cooper

FAGRO (UDELAR)

Montes del Plata

Lignum

Phelox

TABLA DE CONTENIDO

PÁGINA DE APROBACIÓN	II
AGRADECIMIENTOS	III
RESUMEN.....	VI
SUMMARY	VII
1. <u>INTRODUCCIÓN</u>	1
1.1. JUSTIFICACIÓN Y MARCO DE ESTUDIO	1
1.2. SISTEMAS MECANIZADOS DE COSECHA FORESTAL	3
1.2.1. <u>Descripción de un harverster</u>	5
1.2.2. <u>Cabezal cosechador</u>	6
1.2.3. <u>Procedimiento operativo de cosechadoras forestales</u>	7
1.3. DEFINICIONES PARA ESTUDIOS DE PRODUCTIVIDAD EN OPERACIONES DE COSECHA FORESTAL	7
1.4. TERMINOLOGÍAS DE TIEMPOS EN OPERACIONES FORESTALES (IUFRO)	9
1.5. RECOLECCIÓN DE DATOS POR COMPUTADORA A BORDO BAJO ESTANDARES "Standard for Forestry Data and Communication"	15
1.6. VARIABLES QUE AFECTAN LA PRODUCTIVIDAD DE MAQUINARIA FORESTAL EN COSECHA	17
1.6.1. <u>Aspectos del bosque</u>	18
1.6.2. <u>Aspectos del producto procesado</u>	18
1.6.3. <u>Aspectos del operador</u>	19
1.7. ANTECEDENTES DE MODELOS DE PRODUCTIVIDADES MEDIDAS EN URUGUAY	20
1.8. ANTECEDENTES SOBRE CURVAS DE APRENDIZAJE EN MAQUINARIA FORESTAL	22
2. <u>LEARNING CURVE ASSESSMENT OF HARVESTER OPERATOR ON MECHANIZED FOREST LOGGING</u>	25
2.1. ABSTRACT	26
2.2. INTRODUCTION	27
2.2.1. <u>Harvester Productivity</u>	27
2.2.2. <u>Human influence in productivity</u>	29

2.2.3. <u>Learning Curve</u>	30
2.2.4. <u>Selecting harvester operators</u>	31
2.3. MATERIALS AND METHODS.....	32
2.3.1. <u>Criteria for discarding data</u>	35
2.3.2. <u>General analysis</u>	36
2.3.3. <u>Individual analysis</u>	36
2.3.4. <u>Correlations</u>	37
2.4. RESULTS.....	38
2.4.1. <u>General model</u>	38
2.4.2. <u>Individual Analysis</u>	41
2.4.3. <u>Correlations</u>	44
2.5. DISCUSSION.....	45
2.6. CONCLUSIONS.....	48
2.7. ACKNOWLEDGMENTS:	49
2.8. REFERENCES	49
3. RESULTADOS Y DISCUSIÓN GENERAL	55
3.1. <u>RESULTADOS</u>	55
3.2. <u>DISCUSIÓN</u>	57
4. CONCLUSIONES	60
5. BIBLIOGRAFÍA	61

RESUMEN

En el complejo forestal de Uruguay, la madera con destino a celulosa es el sector con mayor relevancia económica; impulsado principalmente por la instalación de industrias de gran porte que demandan anualmente cerca de 9.000.000 de metros cúbicos de madera, lo que representa un 60% del total cosechado anualmente. En el complejo forestal, la cosecha es una de las actividades que tiene relevancia en el precio final del producto. Por esto, en los últimos años se han realizado estudios para evaluar su productividad, en busca de mejorar la optimización del proceso. Hay numerosos factores que influyen en la productividad de la maquinaria forestal y uno de ellos es el factor humano, del cual existe muy poca investigación a nivel mundial y menos aún a nivel local. Un operador con habilidades es esencial para maximizar la inversión de la maquinaria, cuya performance incrementa con el grado de experiencia. En Uruguay no hay antecedentes sobre estudios que analicen el desempeño durante la etapa de aprendizaje de los operadores de *harvester*. En este marco, se desarrolló este estudio que analiza el modelo que mejor se ajusta al aprendizaje de operadores de *harvester*, en función de las horas de trabajo acumuladas. Por otra parte, se evaluó la correlación entre la performance en etapas tempranas del aprendizaje y la productividad final de los operadores cuando la misma se estabiliza. El estudio determinó que a un operador le lleva en promedio 975,4 horas productivas acumuladas de trabajo para que su productividad se estabilice. Esto significa un tiempo aproximado de 6,5 meses para las condiciones de trabajo que enmarcan este sector. El modelo que mejor se ajustó para describir la curva de aprendizaje es una función monomolecular, con mayores incrementos en las primeras etapas, los cuales van decreciendo a lo largo del tiempo hasta estabilizarse. Se identificaron diferencias significativas en la performance entre operadores, tanto en las diferentes etapas del aprendizaje como al finalizar. Por último, se encontró una correlación alta entre el desempeño de operadores en etapas tempranas del aprendizaje con su desempeño final; representado por un coeficiente (*r*) de 0,84 entre la productividad ya a las 100 horas de trabajo acumulado y la productividad final, con un grado de significancia alto (*p* valor menor a 0,01)

Palabras clave: Curva de aprendizaje; productividad; factor humano; manejo de harvester; operador forestal.

LEARNING CURVE ASSESSMENT OF HARVESTER OPERATOR ON MECHANIZED FOREST LOGGING

SUMMARY

In the forest complex of Uruguay, wood for pulp proposes is the area with more economic relevance; mainly driven by the establishment of large industries which demand annually near 9,000,000 cubic meters of wood, representing 60% of the total wood annually harvested. In addition, logging activities has great relevance in the final price of the product. For this reason, in recent years, different studies have been done to assess productivity and efficiency to optimize the whole forest logging process. There are many factors that influence forest machines productivity and one of them is the human factor, of which there is a lack of research worldwide and even less at the local level. An operator with skills is essential to maximize the investment of machinery and performance of an operator increases with the degree of experience. In Uruguay there is no background on studies conducted, which analyze the performance during learning to achieve efficient harvester operators. In this framework, this study is developed to analyze the duration and model that fits best the learning of harvester operators based on the accumulated working hours within the wood production scenario of the pulp industry. Furthermore, it is evaluated whether there is a correlation at certain earlier evaluation moments of learning with final values of the operator performances. As a general result, it can be stated that an operator takes an average of 975.4 working hours to stabilizes its productivity; this means an approximate period of 6.5 months, depending on the shifts schedules of different companies. Besides, the model best fit best to describe the learning curve is a monomolecular function, with greater increases of performance in the first stages and constant decreasing increments until stabilize. On the other hand, there are significant differences in the performance between operators, both in the early stages of learning and at the final performance (end of learning). A correlation coefficient (r) of 0.84 was established between performance of the operators after the 100 productive working hours and their performance when stabilized, with a high significance level (p value less than 0.01)

Key words: Learning curve; productivity; human influence; harvester operation; forest operator.

1. INTRODUCCIÓN

1.1. JUSTIFICACIÓN Y MARCO DE ESTUDIO

Desde la creación de la ley forestal 15.939 el 28 de diciembre de 1987, la actividad forestal en Uruguay ha tenido un desarrollo sostenido. Un ejemplo de esto es la superficie de plantaciones forestales que ha aumentado de 44 mil hectáreas en el año 1988 a cerca de 1 millón en la actualidad, mientras que área de bosque nativo se mantiene aproximadamente en 750 mil (MGAP DGF, 2018).

Esta expansión generada en plantaciones con fines comerciales, que determina la presencia de un gran volumen de materia prima (madera), también se acompaña por la instalación de proyectos de gran porte principalmente en la industria de celulosa (Uruguay XXI, 2017).

Dentro del sector forestal, el complejo dedicado a la industria de celulosa es el de mayor importancia económica y generación de mano de obra. Su desarrollo comienza principalmente con la instalación de UPM-Kymmene Corporation en el año 2008, con una capacidad de 1,2 millones (M) de toneladas de celulosa anuales, la que se incrementa a 1,3 M en el año 2014. Por otra parte, en el año 2013 se suma la instalación de Montes del Plata, produciendo aproximadamente 1,4 M de toneladas de celulosa. El funcionamiento de ambas plantas significa que actualmente es necesario la cosecha de aproximadamente 9 M de metros cúbicos de madera para satisfacer la demanda de estas dos industrias. En su totalidad, en el año 2017, el sector para la celulosa cubría aproximadamente un 63% de la cosecha anual que se realiza en Uruguay (MGAP - DGF 2018, Uruguay XXI 2017).

En este contexto, las operaciones forestales han tendido a mecanizarse fuertemente en los últimos 10 años. Este aumento se debe a varios factores, entre ellos: la disminución de los riesgos de accidentes, el requerimiento de la industria instalada por tener un flujo ininterrumpido de materia prima (madera) con independencia de

eventos climáticos (por ejemplo, lluvia) y la necesidad de disminuir los costos, que a su vez permitan que toda la cadena de operaciones forestales sea social y ambientalmente sustentable (Malinovski y Malinovski, 1998).

La utilización de máquinas de alta tecnología, como el *harvester* (*cosechadora*), aumenta considerablemente los rendimientos de la cosecha y la seguridad en el trabajo, en virtud de que esta máquina es 880% más productiva que una motosierra (Magalhaes y Katz, 2010). Actualmente, el mundo la industria forestal utiliza miles de *harvester* para la cosecha de madera. El alto costo de estos equipos lleva a que deban alcanzar altos niveles de productividad, para lograr ser amortizados de manera económicamente viable. Muchos factores afectan la productividad de una maquina forestal, pero uno de ellos y que muchas veces no es tomado en consideración es el factor humano. Un operador con destreza es esencial para maximizar una inversión en este tipo de maquinaria (Kirk et al., 1997). En este contexto, el entrenamiento y la educación del personal para la industria forestal son críticos en cualquier estrategia para mejorar las prácticas de cosecha forestal (FAO, 2001).

El parque de maquinarias existente en el sector de cosecha forestal uruguayo, al comienzo de la operación de la primera planta de celulosa, apenas superaba el centenar, actualmente el sector superaría las 350 máquinas (Lorenzo 2010 y datos estimados por el autor). De esta forma, para atender esta demanda, surge la necesidad de operadores capacitados para manejar la maquinaria forestal existente. Actualmente, en Uruguay se estima una población de aproximadamente 1.000 operadores activos de maquinaria forestal (datos estimados por el autor). Pero la necesidad de seguir formando operadores es continua por diferentes motivos, entre ellos: recambio natural que se da al llegar a la edad de retiro, recambio para mejorar la productividad de máquinas que están produciendo debajo del óptimo, competencia con otros sectores, tendencia en el aumento de las horas operativas de la maquinaria disponible, espacio para la sustitución tecnológica de cosecha forestal, alta rotación de personal, entre otras. A todo esto se suma los anuncios sobre la posible instalación de una nueva planta

de producción de celulosa, la que demandaría aproximadamente 7,5 M de metros cúbicos adicionales de madera (UPM, 2017).

Dentro del marco descripto, este estudio plantea los siguientes objetivos:

- (1) identificar un modelo que mejor se ajuste a la curva de aprendizaje de operadores en *harvester*, en función de las horas de trabajo acumuladas dentro del marco de cosecha forestal para la industria de celulosa,
- (2) estimar el tiempo que requiere a un operador para alcanzar su productividad estable potencial,
- (3) determinar la correlación entre evaluaciones tempranas de aprendizaje de un operador y su performance final en términos productivos.

Atendiendo a estos objetivos, los resultados generan para las empresas forestales una herramienta con la cual podrán proyectar y planificar su nivel de producción cuando los operadores deban pasar por un proceso de aprendizaje; por lo tanto, podrán dimensionar los recursos necesarios para alcanzar niveles mayores de control. A su vez, ofrece la posibilidad de manejar presupuestos dentro del área de entrenamiento de cada empresa. Por otro lado, para entidades educativas en esta área, el conocimiento del comportamiento de la curva de aprendizaje de maquinaria forestal se transforma en un insumo para disponer de las horas de entrenamiento requeridas, entre otros.

Por último, este estudio será presentado como un artículo que se enviará a la revista International Journal of Forest Engineering. Dicho artículo, se encuentra en el capítulo 2 del presente trabajo.

1.2. SISTEMAS MECANIZADOS DE COSECHA FORESTAL

Malinovski y Malinovski (1998) definen sistema como el conjunto formado por elementos y procesos, siendo definida la cosecha de madera definida como toda la

cadena de producción, desde el apeo de árboles hasta la puesta en el patio de la industria. De esta forma, se podría decir, que la cosecha forestal es el conjunto planificado de actividades relacionadas con la corta, procesamiento, extracción y carga de trozas u otras partes aprovechables de los árboles, para su posterior transformación final, considerando sus efectos a corto, mediano y largo plazo sobre los recursos naturales y el entorno social (Daniluk, 2002).

La cosecha forestal mecanizada ha significado un proceso continuo de mejorías en las condiciones de trabajo, la reducción del costo final de la madera puesta en planta, de regular abastecimiento y reducir los índices de accidentes de trabajo (Da Silva, 2012).

Según Uusitalo y Pearson (2010), se pueden clasificar los métodos de cosecha de acuerdo a como se procesa y extraen las trozas del rodal forestal. A su vez, según la combinación de tecnologías (maquinaria) utilizada para cada método, se puede definir el sistema de cosecha forestal. Se pueden definir 3 principales métodos de cosecha forestal:

- Método de corte a medida (*cut to length*): los árboles son procesados en el lugar que son derribados, siendo extraídos a borde de camino o canchas temporarias en forma de trozas. Para este método, el sistema por convención es harvester y forwarder: *harvester* para el apeo de árboles y, su posterior procesado (desramado, descortezado, corte a medida) y semi apilado en el campo para luego ser extraído a borde de camino o patio de acopio temporario a través de un *forwarder* o autocargador.
- Método de fuste completo (*tree length*): los árboles son semi-procesados (descortezados y derramados) en el lugar que se los apeó, siendo llevados posteriormente al borde de camino o cancha temporaria de acopio en forma de fuste. En general el apeo y semi-procesado se realiza con *harvester* y luego el movimiento a camino o playa de acopio intermedio se hace con *Skidder*” o

Clam Bunk. El trozado final para este tipo de sistema se realiza con motosierra o con un sistema de sierra automatizado (*Slasher* o *Harvester*).

- Método de árboles entero (*full tree*): el árbol es apeado (generalmente con *Feller Buncher* o motosierra) y llevado a borde de caminos o para un patio intermedio (generalmente con *Skidder*), donde es posteriormente procesado (con motosierra o con procesador).

Si bien existen los esquemas clásicos, estos métodos de cosecha forestal pueden ser realizados con diferentes configuraciones de equipos y/o maquinaria (sistema). El más utilizado en Uruguay es el método de corte a medida, donde la configuración clásica o sistema de cosecha es un esquema mecanizado con *Harvester* en la corta y procesamiento de la madera y *Forwarder* para la extracción de la madera a borde de camino o cancha temporaria de acopio.

1.2.1. Descripción de un harvester

Varios autores describen a la cosechadora *Harvester* como una máquina autopropulsada con la capacidad de apear, desramar, trozar y de realizar otras funciones, como apilado y clasificación de las trozas en el rodal forestal (Tolosana et al., 2004).

También definido como máquina con la finalidad de cortar y procesar árboles dentro del monte, que posee un conjunto motriz de alta movilidad y buena estabilidad, pudiendo ser de neumáticos o de orugas. Posee un “cabezal” con múltiples funciones, que se encuentra acoplado a un brazo hidráulico o lanza. El cabezal tiene las funciones de apeo, desrame, descortezado, trozado y apilado. La potencia del motor varía de acuerdo con el modelo, entre 70 y 170 kW, y el peso total entre 8.500 y 16.500 kg (González et al., 2014).

Un equipo está constituido por una máquina base, una grúa y un cabezal procesador, teniendo un radio de acción aproximadamente 10 m, dependiendo del modelo.

Respecto a la vida útil, en general para los cabezales es de aproximadamente 12 mil horas (2 años y medio dependiendo del régimen de trabajo) y para la máquina base y grúa de aproximadamente 20 a 25 mil horas (Linhares et al., 2012).

Los harvester son máquinas de avanzada tecnología y muy bien aceptadas por su capacidad de trabajar en condiciones variables y situaciones adversas. La situación ideal de operación es encontrada en plantaciones comerciales (por ejemplo en marcos de plantación de 3x3m) con árboles de volúmenes entre 0,25 y 0,35 m³ por árbol, no siendo indicados su uso para cosechar en montes con volúmenes por debajo de los 150 m³ ha⁻¹ (Burla, 2008).

1.2.2. Cabezal cosechador

El cabezal es una estructura de acero implementada con diferentes elementos que permiten sujetar, cortar, facilitar el avance y medir por sensores el fuste en proceso, lo que permite cuantificar la producción a través de una computadora ubicada en la cabina.

El cabezal se constituye de un sistema de corta en forma de sierra de cadena encargado de realizar los cortes; un sistema de sujeción de brazos o garras que tienen la finalidad de sujetar el árbol luego del corte, descortezado y desramado; y un sistema de rodillos dentados encargados de desplazar el árbol horizontalmente de un lado al otro.

Además, presenta un sistema de medición de largo y de diámetro; el primero puede ser a través de una rueda dentada que gira a medida que se desplaza el árbol o dentro de los propios rodillos encargados de desplazar el árbol. Para la medición del

diámetro, lo más común es a través de sensores que se encuentran en los cilindros hidráulicos encargados de abrir y cerrar las cuchillas o brazos. Estos sistemas de medición, el sistema de corte, los cilindros encargados de posicionar el cabezal para el apeo y demás componentes están comunicados con la computadora de abordo, generando y registrando la información correspondiente de cada árbol que ha sido cortado.

1.2.3. Procedimiento operativo de cosechadoras forestales

El harvester fue diseñado para convertir el árbol en trozas de diferentes medidas según el tratamiento a realizar, para luego ser asistido por un tractor autocargador o Forwarder y realizar la extracción de la madera a borde de camino o cancha temporal de acopio (Parra y Carey, 2000).

El harvester se va desplazando a medida que va procesando los árboles que tiene en su radio de alcance. Primero, se traslada para llegar al rodal donde va a realizar la corta y allí va haciendo desplazamientos intermedios a medida que va procesando árboles. La máquina, luego de cada desplazamiento intermedio se estaciona y opera la grúa situando el cabezal en la base del árbol y lo apea, pasando a posicionarlo horizontalmente, momento a partir del cual empieza a actuar como procesador del árbol, desramándolo y trozándolo, también en muchos casos descortezándolo. Solo cuando ha concluido de procesar un árbol, la maquina empieza el apeo de otro árbol, conformando de esta manera los ciclos de trabajo de la cosechadora forestal o Harvester (Tolosana et al., 2004).

1.3. DEFINICIONES PARA ESTUDIOS DE PRODUCTIVIDAD EN OPERACIONES DE COSECHA FORESTAL

Durante muchos años se ha conocido al estudio del trabajo como “estudios de tiempos y movimientos”; estos estudios se utilizan con el propósito de conocer la productividad de la maquinaria y también para mejorar su eficiencia operacional. Los

datos que se obtienen de los estudios de tiempos son la base para la toma de decisiones en aspectos relacionados al planeamiento, organización y ejecución del trabajo, establecimiento de metodología en materia de remuneración, de tarifas de servicios, entre otros (Ponse et al., 2015).

Se define el “estudio de tiempos de trabajo” como un estudio detallado de la distribución del uso del tiempo en las diversas tareas que componen un determinado esquema de trabajo, incluyendo también el estudio del tiempo consumido por otros eventos ajenos en principio al objetivo de trabajo, como retrasos, pausas, incidentes, entre otros (Torrijos y Tolosana, 2016).

El estudio de tiempos consiste en la medida, clasificación sistemática y análisis crítico del tiempo empleado en el trabajo para determinar la eficiencia, la productividad y el costo de la realización del trabajo. La medida cuantitativa del tiempo empleado en cada operación o conjunto de operaciones, conocido como ciclo, tiene como objetivo identificar la secuencia, movimiento de los trabajadores, máquinas y material o frecuencia de utilización, además de conocer los parámetros de influencia.

El ciclo de trabajo que permite la evaluación de un sistema de cosecha o un equipo en particular requiere necesariamente de una determinación clara y precisa del proceso mediante el cual se alcanza un objetivo (Parra y Carey, 2000). Por lo tanto, en el caso del trabajo con harvester, corresponde a las acciones que se ejecutan para convertir un árbol a materia prima utilizable o bien las acciones que constituyen su ciclo de trabajo: apeo, descortezado, desramado, trozado, apilado en sitio forestal, entre otros.

Para un mejor entendimiento de los sistemas, se expresa que los modelos de tiempos suelen descomponer el tiempo observado en categorías. Lo usual en los trabajos forestales es la descomposición de este trabajo productivo en una serie de operaciones, formando ciclos de trabajo tales como el corte del árbol y la elaboración

del producto (descortezado, trozado, etc.), por lo que el árbol suele ser una unidad cíclica (Torrijos et al., 2016).

1.4. TERMINOLOGÍAS DE TIEMPOS EN OPERACIONES FORESTALES (IUFRO)

A nivel internacional existe una nomenclatura común referida a operaciones forestales definida por la *International Union of Forest Research Organizations* (IUFRO) que es usada para el estudio de tiempos del trabajo forestal, que puede ser empleado en cada operación elemental de un determinado ciclo de trabajo. Este ciclo se define como una sucesión de trabajos que se aplican de forma repetida a cada objeto del trabajo. Luego, un elemento de trabajo se considera como una subdivisión de una tarea determinada de trabajo que está limitada por puntos de interrupción. Dependiendo de su existencia en cada ciclo de trabajo, un elemento de trabajo puede considerarse como elemento repetitivo o como elemento ocasional (Björheden y Thompson, 1995).

En la Figura 1, se expone la estructura de los elementos del tiempo de trabajo principales que se observan durante los estudios de tiempos.

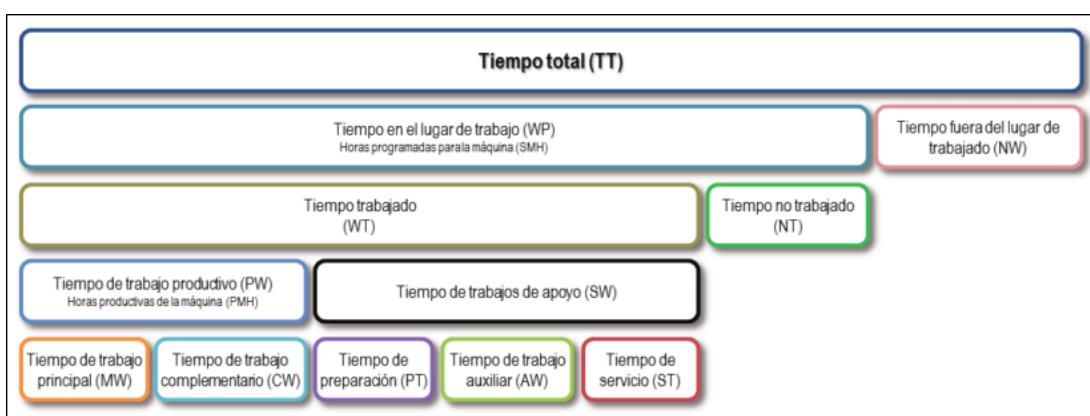


Figura 1. Componentes básicos de la distribución del tiempo de trabajo (adaptado de IUFRO, 1995).

A continuación, se describe la clasificación para el estudio de tiempos de trabajo acorde a la metodología propuesta por IUFRO (Björheden y Thompson 1995):

- **TIEMPO TOTAL (TT):** Tiempo total transcurrido del periodo considerado, también como tiempo calendario.
 - **TIEMPO FUERA DEL LUGAR DE TRABAJO (NW):** La porción del tiempo total que no es utilizado como complemento de una tarea o trabajo específico que se está evaluando.
 - **Tiempo inutilizado (UN):** La porción del tiempo fuera del lugar de trabajo (NW) que el trabajador está completamente fuera de su lugar de trabajo, por ejemplo, el tiempo de descanso en su vivienda correspondiente.
 - **Tiempo de traslado (TR):** La porción del tiempo fuera del lugar de trabajo (NW) que el trabajador se encuentra viajando hacia y desde el lugar de trabajo antes y después del periodo de trabajo evaluado.
- **TIEMPO EN EL LUGAR DE TRABAJO (WP):** La porción del tiempo total que el sistema de producción o parte del sistema de producción está comprometido en una tarea específica. También llamado tiempo programado.
 - **Tiempo no trabajado (NT):** La porción del tiempo en el lugar de trabajo en el cual ninguna tarea se está realizando de las referentes al trabajo establecido.
 - **Tiempo de distorsión (DT):** La porción del tiempo no trabajado que es considerada como interrupción del trabajo sin directa o indirecta conexión a tareas complementarias para realizar el trabajo. Ejemplos de este caso son: inclemencias del tiempo que no permitan

continuidad de alguna tarea, accidentes, dispersión del trabajador.

- **Tiempo en demoras relacionadas al trabajo (WD):** La porción del tiempo no trabajado que puede ser relacionada con la organización del trabajo.

- **Tiempo para alimentación (ME):** La porción del tiempo en demoras relacionadas al trabajo utilizado para alimentación de los trabajadores dentro del sistema de producción, puede ser desayuno, almuerzo, cena, etc.
- **Descanso y tiempos personales (RP):** La porción del tiempo en demoras relacionadas al trabajo utilizado para mantener la capacidad de trabajo de los trabajadores en el sistema de producción, como recreos, descansos, necesidades personales, etc.
- **Tiempo de interferencia (IT):** La porción del tiempo en demoras relacionadas al trabajo en el cual no ocurren actividades de trabajo por interferencias necesarias de operación dentro del sistema de producción; tales como esperas por terminación de alguna tarea que se está evaluando de manera dependiente.

- **Tiempo de trabajo (WT):** La porción del tiempo en el lugar de trabajo que el sistema de producción o parte del mismo está

directa o indirectamente involucrado en completar una tarea específica del trabajo.

- **Tiempo productivo de trabajo (PW):** La porción del tiempo de trabajo que es utilizado en contribuir directamente en la terminación de una tarea específica del trabajo, comúnmente ocurre en base de ciclos (también llamado tiempo directo de trabajo).
 - **Tiempo principal de trabajo (MW):** La porción del tiempo productivo de trabajo utilizado en cambiar de objeto de trabajo con respecto a la forma, posición o estado dentro de la definición de la tarea del trabajo, como ser apeando, desramando, procesando, arrastrando, cargando, etc.
 - **Tiempo de trabajo complementario (CW):** La porción del tiempo productivo de trabajo que no está cambiando de objeto de trabajo con respecto a la forma, posición o estado, pero es necesaria para completar la tarea de trabajo y es parte integral del ciclo de trabajo; como ser posicionar la maquina o el trabajador, limpieza del área de trabajo, evaluación de una situación específica, movimiento de la máquina para dirigirse a cortar árboles, etc.
- **Tiempo de trabajo de apoyo (SW):** La porción del tiempo de trabajo que no agrega directamente sobre la terminación de una tarea del trabajo, pero es realizada

para dar soporte al trabajo. También se le conoce como tiempo de trabajo indirecto.

- **Tiempo preparatorio (PT):** La porción del tiempo de trabajo de apoyo utilizado para preparar las máquinas y las condiciones del lugar de trabajo para un sitio de trabajo o localidad de trabajo.
- **Tiempo de reubicación (RL):** La porción del tiempo preparatorio que es utilizada para el transporte de máquinas o trabajadores, etc., de un sitio de trabajo a otro nuevo sitio.
- **Tiempo de planificación (PL):** La porción del tiempo preparatorio utilizada para desarrollar estrategias operacionales, como planificar el corte de determinada área, trazar rutas de extracción o identificar zonas sensibles, etc.
- **Tiempo preparatorio operacional (OP):** La porción del tiempo preparatorio utilizado para que el sistema de trabajo continúe en un sitio particular, como el cambio de operarios, transporte del operario hacia un determinado rodal, etc.

- **Tiempo de entrada/salida (CO):** La porción del tiempo preparatorio utilizado para configurar y tomar la información de producción.

- **Tiempo de configuración (SU):**

La porción del tiempo entrada/salida utilizado para la configuración del sistema de operativo en una nueva área de trabajo.

- **Tiempo de toma de datos (TU):**

La porción del tiempo entrada/salida utilizado para tomar los datos al moverse a una determinada área de trabajo.

- **Tiempo de servicio (ST):** La porción del tiempo de trabajo de apoyo utilizado para sostener la capacidad de trabajo de las máquinas en el sistema de producción.

- **Tiempo en reparaciones (RT):** La porción del tiempo de servicio utilizado para reparar componentes dañados, que ocurren principalmente como interrupciones no cíclicas, como reparaciones de partes estructurales, esperas para reparaciones, etc.

- **Tiempo de mantenimiento (MT):** La porción del tiempo de servicio utilizado para compensar el sucesivo uso de la herramienta o maquinaria, con ocurrencia de interrupciones principalmente cíclicas, como calentamiento del equipo, chequeo de equipamientos, etc.
- **Tiempo para suministrar combustible (RF):** La porción del tiempo de servicio utilizado para repostar el combustible de la maquinaria o herramientas utilizadas.
- **Tiempo de trabajo auxiliar (AW):** La porción del tiempo de trabajo de apoyo utilizado para realizar trabajos auxiliares que permitan la continuidad del trabajo en el sistema de producción, como asistir a otra máquina o trabajador, acondicionar humedales, etc.

1.5. RECOLECCIÓN DE DATOS POR COMPUTADORA A BORDO BAJO ESTÁNDARES "*Standard for Forestry Data and Communication*" (StanForD)

StanForD es la abreviación para "*Standard for Forestry Data and Communication*". Son estándares de comunicación entre computadoras y maquinaria forestal, que han sido desarrollados y son actualizados por el "*Forestry Research Institute of Sweden*" (Skogforsk). A pesar de que han sido desarrollados en Suecia, estos estándares, son utilizados en muchos países y constituyen el formato de los datos que se generan en la maquinaria forestal del sistema corte a medida (Skogforsk, 2015).

StanForD comprende estándares para los datos recabados, relacionados con la estructura de los archivos e incluso de ciertos protocolos de comunicación entre la computadora de a bordo o el recolector de datos, con los módulos que operan la maquinaria forestal (Skogforsk, 2015) y se constituye en la normativa que rige el lenguaje de la información que genera la maquinaria forestal. Por lo tanto, la información que fluye desde la maquina forestal, que aporta soporte en el control de operaciones, reportes de producción y monitoreo de los tiempos de operación, es registrada de acuerdo con lineamientos enunciados por StanForD.

Los objetivos de estos estándares son alcanzar estructuras de comunicación de datos con los requerimientos actuales de gestión de datos en una manera simple, con prioridades estrictas y reglas de implementación. El foco de estos estándares, es en máquinas forestales del sistema corte a medida (*harvesters* y *forwarders*), para el control, reporte y monitoreo de los momentos de la operación (Skogforsk, 2015). Conjuntamente, estos lineamientos de formatos de datos, al ser el mismo para el universo de fabricantes de harvester y forwarder, permite gestionar bases de datos sin limitaciones por diferencias entre marcas y/o versiones de maquinaria.

A través de la información generada en la maquinaria forestal, es posible desglosar los tiempos de trabajo durante la jornada diaria en detalle, de acuerdo a los archivos generados por la misma.

Tradicionalmente, crear modelos de productividad de maquinaria forestal bajo los conceptos de estudios de tiempo y momentos, requieren de mucha dedicación en horas de campo para la recolección de datos (Stampfer y Steinmüller, 2001). La exactitud de los modelos bajo esta metodología es limitada, por el presupuesto necesario y el tiempo disponible para la recolección de datos. También las habilidades de la persona que toma los datos pueden incidir en los resultados y en la exactitud del modelo de productividad que se está analizando. Por lo tanto, hay una necesidad de simplificar el proceso de toma de datos en una metodología que sea confiable para generar modelos de productividad.

La metodología de toma automatizada de datos de maquinaria forestal es potencialmente más eficiente y económica para determinar la performance de productividad de mayor número de máquinas, operadores y períodos de tiempo. Los datos recolectados por computadoras a bordo de maquinaria forestal para el monitoreo de operadores, ya han sido utilizados en algunos estudios, que como en Purfürst (2010) evaluaron curvas de aprendizaje de operadores y en Olivera et al. (2016), donde evaluaron factores que afectan la productividad del harvester en Uruguay, entre otros.

Por otra parte, para que la información que se genera en computador de a bordo sea de calidad y por lo tanto el análisis que realiza con la misma puedan tener validez, es necesario que a nivel de campo se cumplan ciertos aspectos operativos, como tener un mantenimiento adecuado de los componentes de la maquinaria, realizar calibraciones periódicas y cada vez que se cambia de rodal, realizar un correcto registro por parte del operador en las detenciones de la maquinaria, entre otros.

Strandgard et al. (2013) realizaron un estudio para comparar modelos de productividad de harvester, utilizando datos recolectados de computadoras a bordo de la maquinaria y datos de estudios de tiempo realizados de la forma tradicional. En su análisis no se encontraron diferencias significativas entre las dos metodologías para modelar la productividad; por lo tanto, es posible definir productividades o analizar aspectos de la operación forestal con la información que aporta el computador de a bordo.

1.6. VARIABLES QUE AFECTAN LA PRODUCTIVIDAD DE LA MAQUINARIA FORESTAL EN COSECHA

El desempeño de las máquinas es afectado por diversas variables operacionales, por condiciones del terreno y de la masa forestal. En general, los diferentes escenarios del bosque, como la pendiente del terreno, distancias de extracción, volumen por árbol,

entre otros, influencian directamente la productividad de la maquinaria (Da Silva, 2012).

La capacidad productiva del harvester, está fuertemente influenciada por un gran número de factores ambientales y técnicos. Los principales factores que influyen en el harvester son: clima (lluvia, viento), condiciones de terreno (topografía, capacidad de soporte), características de los árboles (diámetro, tamaño de ramas, calidad de madera) y volumen por árbol (Bramucci y Seixas, 2002). Burla (2008) enumera algunos aspectos del procesamiento como el descorteza y el largo de la madera, que tienen gran influencia en la productividad de la maquinaria.

1.6.1. Aspectos del bosque

Akay et al. (2004) indican que el rendimiento operacional del harvester está muy relacionado al tamaño del árbol, ya que conforme disminuye el volumen de éstos también lo hace el rendimiento operacional.

Simões et al. (2010) encuentran que el diámetro a la altura del pecho (DAP) influencia en aproximadamente un 50% la productividad del harvester. En sus conclusiones destacan un aumento de la productividad de forma lineal en función del DAP, con un coeficiente de regresión de 0,52.

El volumen de madera por hectárea está fuertemente relacionado al volumen individual de los árboles, por lo que es natural que se encuentre una influencia de esta variable sobre la productividad de los harvester (Bramucci y Seixas, 2002).

Holtzcher y Lanford (1997) encuentran que el volumen medio por árbol es la variable que mejor explica la capacidad operacional. A su vez, Da Silva (2012) señala que la variable con mayor influencia en la productividad es el volumen por árbol, representando un 58% de la variabilidad.

1.6.2. Aspectos del producto procesado

Existen otros estudios que evalúan la influencia que pueden tener características del producto a obtener de la cosecha, como el largo de troza. En este caso, se indica que la cosecha de madera de 6 m de largo presenta los mejores rendimientos operacionales (Burla, 2008). El mismo autor, menciona que el largo de la madera afecta significativamente la productividad del harvester, cuanto mayor es el largo de la troza mayor la productividad. En una operación de cosecha con trozas cortas (2 a 2,5 m) la operación pierde de un 20 a un 30% de productividad en relación con el proceso de realizar trozas largas (5 a 6 m). Por otra parte, menciona que la operación de descortezado disminuye la productividad de un harvester entre 10 y 30%.

Bramucci y Seixas (2002) encuentran que la productividad en harvester realizando descortezado es prácticamente lineal a medida que aumenta el volumen hasta estabilizarse en 0,5 m³ por árbol. Esta variable representa en promedio cerca del 55% de la variación productiva del harvester. Los mismos autores, comparando la productividad del harvester con o sin descortezado, señalan que el tratamiento sin descortezado es ligeramente superior en los árboles de menor porte (0,1 a 0,3 m³), aumentando la productividad y acentuando la diferencia en árboles de mayor porte (0,3 a 0,5 m³).

1.6.3. Aspectos del operador

Purfürst y Erler (2011) realizan un estudio de la productividad de diferentes operadores manejando harvester evaluando la influencia del operador en la productividad. Durante el estudio obtienen como resultado que el volumen por árbol y el operador explican el 84% de la variabilidad en productividad, y que el 37,3% de la misma es explicado solo por el operador. Concluyen que la influencia del operador en la productividad es un factor de mucho peso y por lo tanto debe ser considerado como factor clave en los modelos de productividad.

Diferencias de hasta 40% han sido observadas en la productividad entre operadores incluso manejando la misma maquina (Ovaskainen, 2005).

Muchas de las diferencias entre operadores se deben al número de decisiones, que requieren ser rápidas y continuas durante el manejo de la maquinaria (Ranta, 2009). Un operador excelente tiene la capacidad de manejar varios aspectos del trabajo simultáneamente que lo que haría un operador menos eficiente; a modo de ejemplo: el movimiento del extensible simultaneo al movimiento de los tramos de grúa, movimientos del extensible siempre cerca de la máquina, alcanza mejor y más eficiente ángulo de trabajo con la grúa (Väätäinen et al., 2004), además siendo capaz de posicionar las cuchillas del cabezal cortador en el lugar exacto y optimizar los cortes de la sierra (Brunberg et al., 1989). Un buen operador, tiene la capacidad de planificar 4 ó 5 árboles por adelantado (Ranta, 2004) y muestra muy poca variación entre los diferentes árboles que va procesando (Ovaskainen, 2005). Väätäinen et al. (2004) afirman que 10 a 15% de las diferencias en performance de los operadores de harvester se deben a la técnica empleada, 20 a 30% es debido al uso más eficiente de la grúa y el motor y de 50 a 55% son el resultado del mejor planeamiento del trabajo y toma de decisiones por parte del operador.

La influencia del aspecto humano es muy complejo de analizar, debido a que la performance del operador es el resultado de numerosos factores que no son fácilmente medibles, que además pueden tener interacciones adicionales con otras variables (Nurminen et al., 2006).

1.7. ANTECEDENTES DE MODELOS DE PRODUCTIVIDADES MEDIDAS EN URUGUAY

Se han realizado en el país estudios que evalúan la productividad de operadores de maquinaria forestal en cosecha. Todos estos estudios, en general, solo evalúan la productividad de la maquinaria para una determinada especie y un rango acotado de tamaños de árbol.

En un estudio realizado por Rivas y Suárez (2014) se evalúa la productividad de la cosecha mecanizada para *Eucalyptus grandis* W. Hill con harvester. El rango de árboles evaluado fue de 0,20 a 0,5 m³ y el tratamiento de cosecha consistía en trozar madera con un largo de 7,20 metros y descortezado el 100% de la base del árbol. El modelo encontrado corresponde a un modelo lineal en función al volumen por árbol (m³.arb⁻¹) que se representa a continuación:

$$y = 43,62 * x + 7,5654$$

Donde, “y” es la productividad del harvester en m³ por hora efectiva de trabajo (HEfT⁻¹) y “x” es el volumen por árbol (m³ arb⁻¹). En el estudio, se observó una correlación de 0,65 entre productividad del harvester y el volumen por árbol.

Por su parte, Ibarra y Rodriguez (2010) evalúan la productividad de un harvester cosechando *Eucalyptus.maidenni* F. Muell en función del volumen por árbol. Al igual que en el caso anterior, la madera confeccionada corresponde a trozas de 7,20 metros de largo con descortezado completo en la base de primera troza, los árboles cosechados tenían un tamaño de entre 0,20 y 0,30 m³ arbol⁻¹. El modelo de productividad descripto es el siguiente:

$$y = 43,009 * x + 11,643$$

Siendo la definición de los parámetros la misma que en el caso anterior.

Respecto a los modelos mencionados, se determina que cuando las especies representan árboles más derechos y con menos ramas (en este caso *E. grandis*) es esperable una productividad del harvester mayor.

Olivera et al. (2016) evalúan la productividad de varios operadores en diferentes especies de *Eucalyptus spp*. A diferencia de los casos anteriores, aquí los autores además de estudiar el efecto del tamaño del árbol en la productividad, que en este caso

estaba representada como el diámetro a la altura del pecho (DAP), analizaron el efecto de diferentes especies, el turno de trabajo, la pendiente, así como también las interacciones que pudieran existir entre estas variables. No encontraron diferencias significativas por efecto de la pendiente (que cabe mencionar son menores al 10%), ni por el momento del turno (día y noche). Sí señalan que hay efecto de la especie y el DAP. El modelo resultado de este estudio se representa a continuación:

$$\text{Productividad} = e^{b_0 + b_1 \ln(DAP)}$$

Donde, b_0 y b_1 son coeficientes del modelo correspondientes, según cada especie.

1.8. ANTECEDENTES SOBRE CURVAS DE APRENDIZAJE EN MAQUINARIA FORESTAL

Muchos autores estudian la productividad de la maquinaria forestal respecto a variables presentes en el escenario de trabajo en que operan, pero sin considerar los efectos humanos o experiencia de los operadores. El reemplazo de un operador experimentado por un operador nuevo puede ser estimado como una pérdida de producción equivalente a 49,690 euros (Gellerstedt et al., 2005) basado para un escenario de cosecha en países escandinavos, sin aun tomar en cuenta el costo del cursos de simulador.

Para Purfürst (2010) el manejo de un harvester tipo *single grip* (con capacidad para tomar de un árbol), es un trabajo complejo y la performance de quien lo maneja varia con el tiempo. Cuando un operador de harvester comienza su carrera, usualmente tiene un nivel de performance muy bajo. Con el tiempo, el operador comienza a cometer menos errores, aprende a ignorar información no importante y las destrezas de coordinación se incrementan. A través de la repetición de ciclos de trabajo, el operador va desarrollando un modo automático de trabajo donde las funciones empiezan a ser coordinadas por el cerebelo en lugar del cerebro. Con experiencia de

trabajo, obtiene buen entrenamiento y la performance aumenta a través del tiempo. Este efecto es también dependiente de la habilidad del operador (Parker et al., 1996; Purfürst, 2010).

La relación entre la productividad del operador y su experiencia es llamada la curva de aprendizaje (Purfürst, 2010). La curva de aprendizaje describe el nivel de performance a través de este tiempo de aprendizaje. Lo que se asume generalmente, es que mientras más tiempo el operador utiliza la maquinaria, más familiarizado estará con la misma, por lo tanto, sus habilidades de operación se van incrementando.

Parker et al. (1996) estudiaron el aprendizaje de operadores de forwarder y harvester, concluyendo que el incremento mayor de productividad se da en los primeros 30 días de aprendizaje, pero ésta es muy fluctuante.

Bramucci y Seixas (2002) verifican que la experiencia del operador tiene influencia en la productividad de la maquinaria forestal, siendo esta última mayor al aumentar el número de horas acumuladas; sin embargo, marcan que este efecto después de determinada cantidad de horas es muy pequeño.

La curva de aprendizaje puede ser dividida en diferentes segmentos, Stampfer y Steinmüller (2001) sugieren dos fases: la primera llamada de aprendizaje, donde el operador aumenta su productividad continuamente y la segunda, llamada fase de trabajo, donde el operador se mantiene en niveles relativamente constantes de performance.

La duración del periodo de aprendizaje puede ser definido en formas diferentes. Wagner (2004) menciona que para llegar a un nivel de experto se necesitan entre 1.000 a 1.500 horas de máquina productiva. Otros autores lo describen como un periodo tiempo que debería ser entre 8 y 12 meses (Calabrese, 2000).

En el estudio realizado por Purfürst (2010) se examina la duración y la forma de la curva de aprendizaje de operadores en operaciones de raleo en bosques de coníferas en el sur de Alemania. El autor describe la curva de aprendizaje como una función sigmoidea, donde en el comienzo los operadores se ubican entre un 50 y 60% de su productividad potencial, duplicando su productividad al final del tiempo de aprendizaje. El tiempo de aprendizaje que obtuvo se encuentra en un rango de 155 a 488 días (media de 227 días). Concluye que la duración del aprendizaje de un operador forestal es de aproximadamente 8 meses, pero las diferencias y variación en las curvas de aprendizaje entre operadores es grande y por lo tanto generalidades deben hacerse con precaución.

2. LEARNING CURVE ASSESSMENT OF HARVESTER OPERATOR ON MECHANIZED FOREST LOGGING

Gonzalo García^{a*}, Gustavo Daniluk^b, María Virginia Gravina^c

^a Forestry Department, Faculty of Agronomy, Universidad de la República, Montevideo 12900, Uruguay; ^b Forestry Department, Faculty of Agronomy, Universidad de la República, Montevideo 12900, Uruguay; ^c Statistics Department, Faculty of Agronomy, Universidad de la República, Montevideo 12900, Uruguay.

*Corresponding author

E-mail: ggarciafreirel@gmail.com; Tel.: +598 99 601379.

Learning curve assessment of harvester operator on mechanized forest logging

2.1. ABSTRACT

Among many factors affecting harvester productivity, operators' skills and abilities are crucial for overall success of forest logging companies. Moreover, general knowledge about the time frame needed for a harvester operator to reach stable productivity is the main issue when planning production for a learning period. In this study twenty-five operators were assessed during their learning process, which resulted in different skill level development between them. Therefore, correlations were performed to establish whether it is possible to identify more productive operators during earlier stages of the learning process. Data used in this study was obtained from forest machines equipped with on board computers, created by StanForD guidelines. All observed productivities have been relativized by local models using species and volume per tree as dependent variables. According to the results, an average of 974.5 productive working hours are needed for an operator to reach a stable performance. Moreover, for the studied population, a correlation coefficient (r) of 0.87 was established between performance at already 100 accumulated PWH with corresponding final performance. Hence, it can conclude, that operators with higher abilities to operate harvester machines can be spotted already in the initial phases of the learning process. This fact can potentially save time to forest machinery owners when selecting operators, which would furthermore result in an enhanced overall production.

Keywords: Uruguay; learning curve; productivity; human influence; harvester operation; forest operator.

2.2. INTRODUCTION

In the recent history, forest operations in Uruguay had a significant increase due to large industrial investments mostly for cellulose propose, which have a constant need of wood supply. The annual wood flow for the mentioned industry, for the year 2017, reaches around 9 million cubic meters of round wood, which equals to around 63% of the total wood removal (MGAP DGF, 2018; Uruguay XXI, 2017).

In order to fulfil this wood demand in Uruguay, the adopted technology in forest operations is mostly developed by Scandinavian countries under the logging cut-to-length system. Olivera et al. (2016) stated that 60 % of the forest harvesting operations are as described, and harvester – forwarder scheme is widely used.

Lorenzo (2010) quoted that by the year 2008 (before the first large pulp mill started its operations in Uruguay), the total number of forest machines in the forestry sector was roughly one hundred. Currently, with information gathered for this study, the total number of forest machines working in the forest logging sector is around 350. Meaning that, following the forest industry development, the mechanization of forest operations in Uruguay has also grown dramatically during the last 10 years. Consequentially, there is a continuous demand for qualified operators to drive this growing number of machines.

2.2.1. Harvester Productivity

When assessing harvester productivity models, the traditional methodology has mostly been carried out using time and motion techniques, which is largely defined as time and work consuming (Purfürst, 2010; Strandgard et al., 2013). Moreover, these types

of studies have a narrow scope since they are made for a small sample size and short time lapses. On the other hand, automatic data collection by on board computer (OBC), which is a standard equipment on almost every single grip harvester and forwarder, is a potentially efficient and cheaper way of collecting harvester performance data from larger number of harvesters and/or over longer time periods. Despite the fact that logging machines have been equipped with computers on board for already many years, the automated harvest data collection, received little attention to date.

In order to handle same information between different type/brand of machines, OBC collects and stores data of operations regarding international guidelines known as Standard for Forest Machine Data and Communication (Räsänen & Sorsa, 2010; Arlinger et al., 2012; Skogforsk, 2015), abbreviated as StanForD. Strandgard et al. (2013) assess the productivity of harvester machines, comparing traditional techniques and OBC collected data. Among the outcomes, no significant difference has been found between different data collecting methodologies.

Forest harvester machine productivity is a very relevant aspect that must be addressed by every forest company, due to the fact that this type of technology requires large investments and operational costs (Bramucci & Seixas 2002; Akay et al. 2004). The same authors indicate that many factors can influence the productivity of the harvester, among others: slopes, topography, volume per tree, species and volume per hectare are widely mentioned. Kirk et al. (1997) describe that operational productivity of a harvester machine has a strong correlation with the tree size: as volume per tree decreases, productivity (m^3 per hour) also decreases.

Productivity has been studied in *Eucalyptus* spp. plantations in the South America. The factors mostly addressed in those studies are effect of species and volume per tree. Among the results, regression models are obtained for different species and volume per tree is used as a dependent variable (Bramucci & Seixas 2002; Da Silva 2012; Olivera et al. 2016). It is concluded, that higher volume per tree results in a higher productivity (m^3 per hour) of the harvester machine. Regarding different eucalyptus species, when they represent straighter, non-crooked stems and softer branches, higher productivity (m^3 per hour) of harvesters can be expected. Furthermore, Olivera et. al. (2016) also measure other variables in the productivity, such as slopes and shift (day-night) effects, however no significant differences have been observed in the studied scenario. On the other hand, there are significant differences in performances between operators, even though they had the same training programs.

2.2.2. Human influence in productivity

Due to the high capital investment required for mechanized logging systems, a skilled operator is an essential part of profitable and sustainable business plan. Since the unit cost ($US\$ m^{-3}$) is heavily influenced by the production pace, ability to learn new tasks quickly and efficiently, is crucial (Kirk et al., 1997).

Experience and skills of an operator have been an interest of many scientists and authors (Gellerstedt, 2002; Purfürst, 2007; Purfürst & Erler, 2011; Westerberg & Shiriaev, 2013; Häggström, 2015;). Purfürst and Erler (2011) report that at stand level, operators' performances differ by a factor of 2.2 when working at thinning operations in Germany. Furthermore, large productivity differences up to 40% are also observed

for different operators using the same harvester (Kärhä et al., 2004).

The human influence is a hard and complex aspect to asses (Nurminen et al., 2006) but one of the outcomes that various authors mention is, despite the variability between operators, experience is positively correlated with higher performance (Häggström, 2015; Purfürst, 2010).

2.2.3. Learning Curve

The learning curve can be defined as a relation between performance level and the experience of an operator (Purfürst, 2010). It can be expected that the productivity will increase with higher level of experience of the operator. The replacement of an experienced operator by a new harvester operator can be estimated by a production loss of about 49,650 Euros (Gellerstedt et al., 2005); the reason for that is the time needed to reach potential productivity.

Purfürst (2010) studies the learning curve of operators working with conifers in Germany among a variety of scenarios but mainly at thinning operations. It is concluded that it takes around eight months for an operator to achieve a stable performance, although the variability among operators is high. In another study in Canada, it is described that the time span to reach an experienced level goes between 8 and 12 months (Calabrese, 2000).

Learning curve length can also be addressed using number of productive or effective working hours. It is found, that in order to achieve an experienced level operator, the amount of hours needed is between 1000 and 1500 working hours (Wagner, 2004).

In Uruguay, there is a lack of information regarding learning process that an operator must go through when working with forest machines. Furthermore, similar sites of forest production can be found in Brazil and Chile, however we did not find any published study on this regard in South America.

2.2.4. Selecting harvester operators

Selecting an operator is another important area requiring consideration, however there are no established selection programs formalized in Uruguay. Potential losses as a result by selecting operators with low or inappropriate performance, could be extensive (Kirk et al., 1997). Therefore, formal selection and knowledge from the learning programs would improve the chances to employ only suitable candidates. In a competitive market, where efficiency in every process must be accomplished to assure the competitiveness on the long term, skilled operators are essential

Pagnussat and Lopes (2017) state that skills and abilities of the operator are important, however behavioural profile must also be considered to accomplish stable operators. The behavioural profile is defined as an individual's natural predisposition for a particular kind of work. Furthermore, it is argued that to improve the efficiency of forest operations and increase productivity, it is crucial to hire workers with tacit knowledge or natural abilities as well as the right personality, combined with sources of motivation (Parise, 2005; Volodina et al., 2015).

In regard to abovementioned, some questions arise: How long would it take for a new operator to reach an acceptable and stable production when driving a harvester machine? Is it possible to select potentially higher performance operator already in

early learning phases? Hence, the objectives of this study are: a) Describe the learning curve of harvester operator in the Uruguayan scenario for pulp production and b) Measure correlations between initial performances of new operator and final performance after learning period.

With this knowledge, forest companies would improve the ability to identify for how long production, and in turn the operation's cash flow, are likely to be affected by new operators. Furthermore, it would enable them more accurate wood flow plan estimations from newly mechanized logging operations. In addition, the opportunity to identify skilled operators in the early stages of selection, could be an overall production enhancement for logging companies.

2.3. MATERIALS AND METHODS

For a period of three years, from 2014 until the end of 2016, a database of 35 operators with no previous experience has been assessed, collecting every individual productivity over the time throughout their learning process. From those, 25 resulted with accurate information that was incorporated in this study. All operators have gone through the same agenda to operate directly a harvester machine, which included 50 hours of simulator led by harvester professional trainers and then 50 hours of operation *in situ* also escorted by trainers. During the simulation phase, future operators were subjectively evaluated by trainers regarding different aspects of the operation: tree approaching, felling technique, fork stems handling, crane movements coordination, stump height after felling, bucking position, prolixity of processed logs, among others. Furthermore, they were also given theoretical knowledge about forest operations.

After the simulation phase, operators were working directly on the machinery (harvesters). A fleet of 20 harvester provided the data for the whole study. All of them, were brand/model: PONSSE Ergo, crane type: PONSSE C44, and PONSSE H7 harvester head was the most used one. Because all harvesters had the same technology, the effects added by different technologies were avoided. In addition, during the study, clear cut logging methodology was applied and fully debarked of 6,5 meters length logs were produced.

In summary, to accomplish the proposed objectives, during this four-year period of collecting information, it has been gathered a database of 1.634.217 trees, or 337.440 cubic meters of wood, that has been processed.

All machines used, were equipped with OBC and control systems software OPTI 4G Ponsse version 4.728. Data has been processed since operator started working directly in a harvester until their performance showed to be stable. It has been recorded and stored according StanForD standards in defined drf, prd, stm files (Skogforsk, 2015). Among them, drf files were mostly used, which are specific for operational time monitoring and contain complete shift information of events during working hours, detailed in sub shifts. To reduce the influence of time when the machine was not productive, only production related times were included: processing, terrain travel and road travel (Figure 1). According to the methodology proposed by IUFRO, partition of working time corresponds with “productive working time” (PWH) (Björheden & Thompson, 1995). The computer was settled to record down times of more than 3 minutes in length, as it is the common setting for uruguayan

loggers.

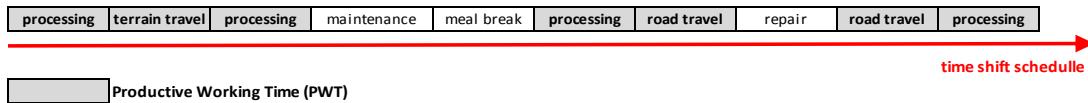


Figure 1. Scheme of time decomposition during working shift, sub shift in drf files, highlighted the time considered for this study. Adapted from StanForD.

During logging, operators were working in different forest stands, in the east and west of Uruguay, all of them *Eucalyptus* ssp. plantations owned by the company Montes del Plata. Before attaining into any stands, the mentioned forest company, provided inventory data with information showed in table 1.

Table 1. Detail of inventory information counted for every stand where the study was carried out

Variable	Description
Stand ID	Identification number
Year	year of plantation
Species	<i>Eucalyptus globulus</i> , Labill <i>Eucalyptus maidennii</i> , F. Muell <i>Eucalyptus grandis</i> , W. Hill <i>Eucalyptus dunnii</i> , Maiden <i>Eucalyptus viminalis</i> , Labill
Regime	Regime of the stand: coppice or
Dt.In.	date when the inventory has been done
Sup	area of the stand in hectares
age	years of the stand
N	trees per hectare
N>8	trees per hectare with commercial value (higher than 8 cm at DBH)
DBH	diameter at breath height (cm)
HM	Medium height of the trees (m)
HD	Dominant height (m)
Va	medium volume per tree (m ³ /tree)
IMA	Medium annual increment (m ³ /year/hectare)
V mcs	commercial volume per hectare
VT	total commercial volume of the stand
E Inv	Error of the inventory
Group specie	Aggrupation regarding specie and location: Glob_1, Glob_2, Maid_1, Gran_1. (Defined for this study)

For the purpose of this study, every stand has been grouped in four categories according to *Eucalyptus* spp. species and location. Then, each group, was assigned by

a corresponding harvester productivity target model (known by historic data of companies involved) with volume per tree as independent variable. Finally, those regression models (target) were used to relativize each instant productivity of operators (observations) while they were accumulating working hours. Therefore,

$$P_R = P_I / P_E \quad (1)$$

Where, P_R is the relativized productivity or Performance, P_I is the observed productivity in $m^3 PWH^{-1}$ or trees PWH^{-1} (observations), and P_E is the expected productivity ($m^3 PWH^{-1}$ or trees PWH^{-1}) according to the harvester productivity target models and the matching inventory data.

Then, considering P_R as a dependent variable and Accumulated PWH (APWH) as independent variable, nonlinear regression models were carried out to establish which model fit best. Therefore, general model as bellow:

$$P_R (f) = APWH \quad (2)$$

Assuming, that models for expected productivity (P_E) are accurate and the sample of operators have a normal distribution, it is expected that the average coefficient of P_R , when operators reach stable productivity, will be close to 1.

All the statistical analyses were carried out with Infostat version 2016 software (Di Rienzo et al., 2016).

2.3.1. Criteria for discarding data

Some observations were discarded from the database. The criteria to limit the dismissed data are detailed as bellow:

- (1) Shifts that the report by operator showed issues with the operative system of the machine, in order to avoid data loaded when the machine could be recording wrong measurements, e.g. sensors issues.
- (2) Shifts that a non-conventional assignment was required, e.g. road edge cuttings.
- (3) Observations with working time laps shorter than 15 minutes or less than 20 processed trees, in order to avoid sub or over valued data.

2.3.2. General analysis

To select which model fitted best, Akaike's information criterion (AIC) at 0.01 level of significance has been used to compare models. Therefore, the model with lowest AIC value is the most suitable to describe the learning curve (Crawley, 2013). A stepwise process, of selecting the best-fit model for the learning curve, has been done for each operator separately, and then, for all the operators together in order to obtain the general model.

Afterwards, tests with the selected models were carried out, to confirm the accuracy. Hence, the fitted model was checked for homoscedasticity and normality, predicted values of the model and observations were used for linear regression to visualize distribution and to obtain parameters such as correlation with the selected model.

2.3.3. Individual analysis

Other analyses were carried out for each operator. First, it was defined the amount of productive working hours needed to reach a stable performance individually. The

learning curve, in general, shows significant increases in productivity over accumulated working hours, which due to the fluctuation of the data and the variability of all factors that influence productivity, does not fall again. For the strong variation of data and the fact that the curve becomes asymptotic, it is not possible to define the end of the learning phase in a purely mathematical way. Therefore, the same approach described by Purfürst (2010) has been used to determine the end of the learning: when the curve shows to reach a stable level and has been recorded the first large maximum, combining visual and mathematical analysis.

Then, for each individual operator, the average performance value at every 50-accumulated productive working hours and corresponding final performance has been estimated. Finally, in order to propose other ways of measuring duration of the learning process, was defined for each operator the required amount of days, processed stems and volume to reach stable productivity.

2.3.4. Correlations

All information has been summarized by initial performance (P_i), every 50-accumulated productive working hours (P_{50} , P_{100} , P_{150} , P_{200} , etc.) and final performance (P_f). This information was settled to assess the strength association between variables: performances at initial stages of the learning process and final performance. Since each of them are continuous variables, Pearson coefficient (R) was carried out to estimate correlations (Chen & Popovich, 2002). Furthermore, Principal Component Analysis was also used to evaluate association among different variables and check previous correlations (Di Rienzo et al., 2016).

2.4. RESULTS

2.4.1. General model

A general model of the learning curve was established with the observations of 25 operators during their learning process. The best fitted model corresponds to a Monomolecular model, meaning that productivity starts at the lowest level, then rises at decreasing rate over time; and finally, at the end, the curve asymptotes. Despite, the Monomolecular model showed to have the lowest AIC coefficient, the Logistic presented a very close value. Regarding this result, Parker et al. (1996) and Purfürst (2010) explain the learning curve as a logistic model with an initial phase of increasing increments that switches to decreasing increments becoming asymptotic at the final phase.

Figure 2 shows the resulted curve, including the dispersion of all observations from this study. Each parameter of the model was obtained with p>values lower than 0,001. Equation (3) presents the general learning model and parameters are shown in Table 2.

$$P_R = [alfa * (1 - beta * e^{(-gamma*APWH)})] \quad (3)$$

Table 2. Parameters alfa, beta and gamma from the learning general model of harvester operators

Parameter	Cota INF	Conta SUP	Initial Value	Estimation	E.E.	T	p-value
ALFA	-1e030	-1e030	1.734	1.030	0.009	111.278	<0.0001
BETA	-1e030	-1e030	0.001	0.734	0.012	60.239	<0.0001
GAMMA	-1e030	-1e030	0.001	0.003	1.3E-04	22.260	<0.0001

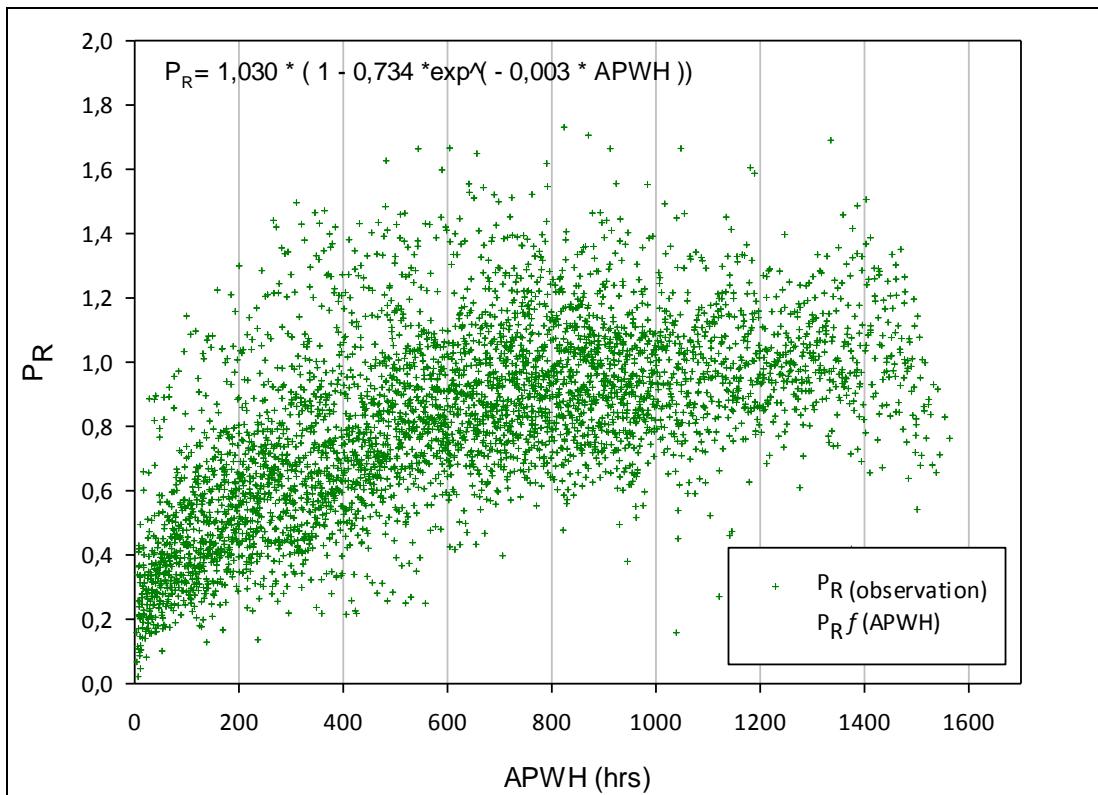


Figure 2. Performance distribution regarding accumulated Productive Working Hours for all operators and regression learning model

The resulted learning model showed that performance of an average operator at initial time, when operating harvester machine, is placed in 27.4% of the potential. The average increment, in relative terms of productivity, was 0.08% per PWH; and higher rates were at the beginning, reaching 47.0% of the potential productivity within 100 PWH (performance increased at this phase by 0.21% per PWH).

Figure 3 shows a coefficient of determination (r^2) 0.469 between prediction of the model and observations, therefore, 46.9% of variability in all observations is explained by the model. Regarding distribution of the standardized residuals, showed in the Figure 4, a normal distribution is observed. In both figures, gathering of observations towards value 1 is noted, meaning that the performance of operators was

stabilized at this level, hence, previous local productivity regression models were suitable for type of production and studied forest scenarios.

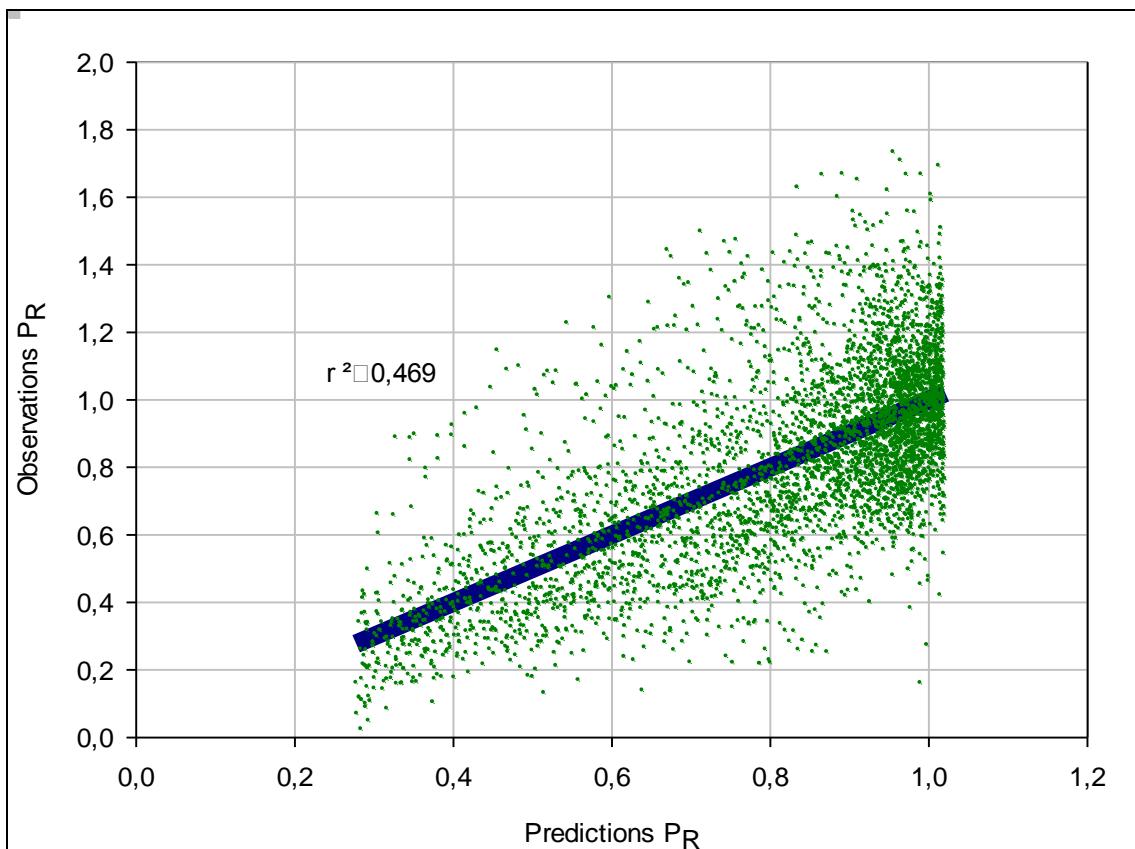


Figure 3. Linear regression with predicted values from the general model and observations

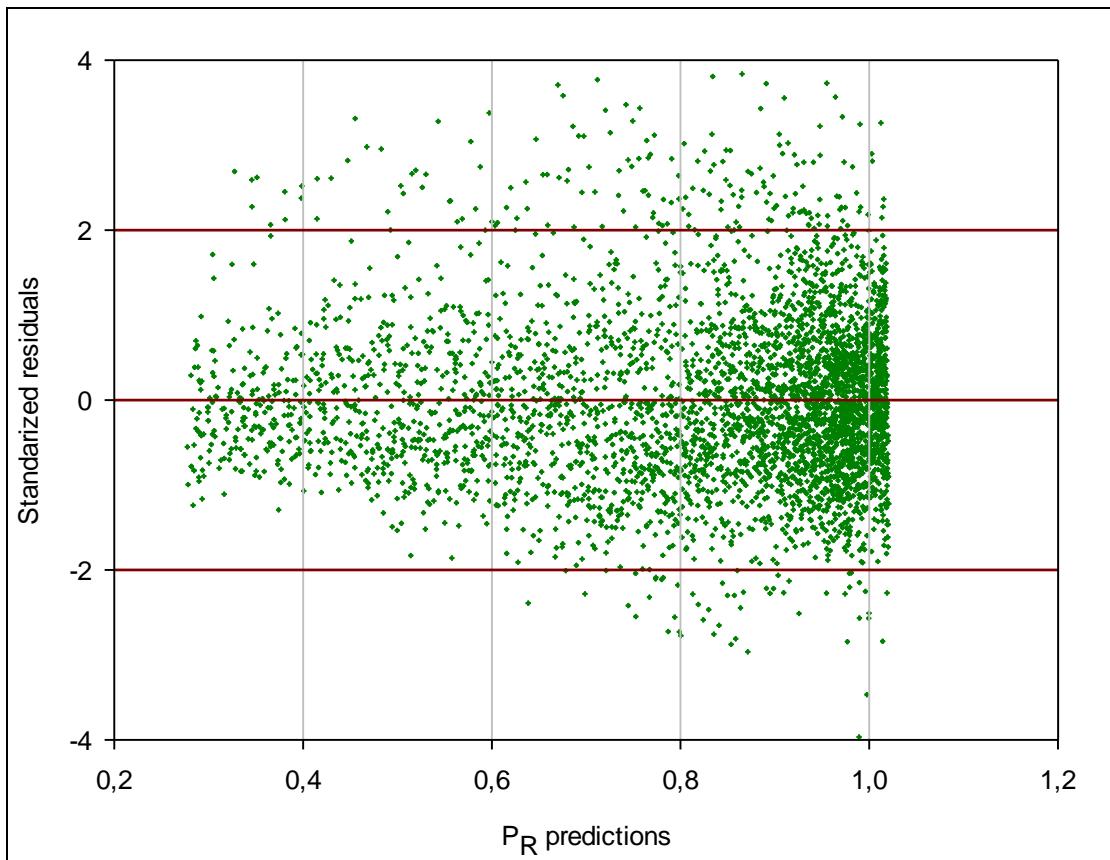


Figure 4. Standardized residuals distribution for general model

2.4.2. Individual Analysis

Some of the individual models (which fitted best for each individual operator) are represented in Figure 5, then, summary of the analysed data on Table 3.

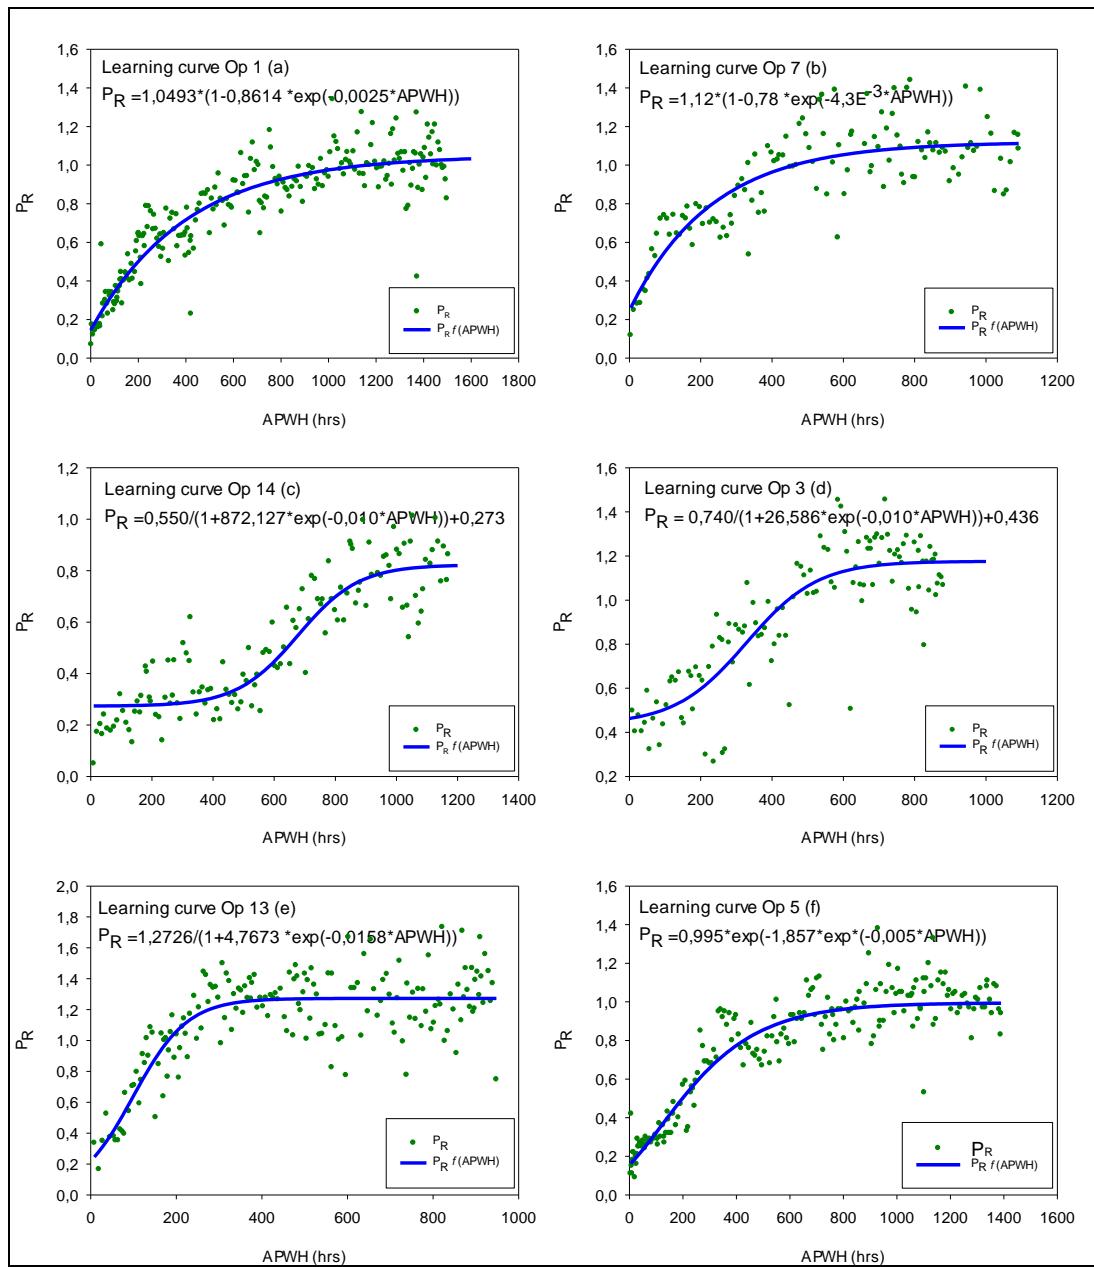


Figure 5. Individual learning models for a sample of studied operators, where: **a** and **b** corresponds to Monomolecular model; **c**, **d** and **e** corresponds to Logistic model; and **f** correspond to Gompertz model.

Table 3. List of operators with corresponding data of: coefficient of determination (r^2) for the fitted individual model, performances level at different accumulated working hours (Pi, P50, P100, P200, P500, P750, P1000), final performances (Pf) and amount of PWH to reach final performance. In the bottom of the table are the average values (**Average**) for each variable and the predicted values from de General Model (**G Model**).

Op.	r^2	Pi	P50	P100	P200	P500	P750	P1000	Pf	hrs._
1	0.84	0.138	0.264	0.332	0.547	0.813	0.950	1.027	1.029	1016.8
2	0.52	0.500	0.834	0.688	0.803	1.155	1.181	1.432	1.320	1046.1
3	0.74	0.450	0.449	0.518	0.579	1.090	1.205	1.175	1.157	717.9
5	0.81	0.188	0.255	0.308	0.453	0.736	0.906	1.054	1.000	929.0
7	0.70	0.216	0.417	0.701	0.726	1.143	1.112	1.223	1.098	788.2
8	0.45	0.377	0.892	1.050	1.092	1.292	1.292	1.359	1.376	587.3
9	0.83	0.205	0.323	0.460	0.560	0.870	0.977	1.047	1.040	890.8
11	0.89	0.227	0.265	0.346	0.506	0.945	1.041	1.104	0.998	742.9
13	0.67	0.250	0.395	0.672	0.986	1.319	1.144	1.270	1.258	602.2
14	0.82	0.111	0.194	0.238	0.334	0.362	0.673	0.812	0.803	1052.9
15	0.76	0.270	0.323	0.320	0.489	0.575	0.798	0.877	0.849	1014.5
16	0.60	0.258	0.386	0.550	0.577	0.899	0.960	1.043	1.107	1168.0
17	0.65	0.266	0.362	0.522	0.614	0.708	0.801	0.938	1.043	1187.5
19	0.62	0.259	0.277	0.559	0.577	1.083	0.923	1.024	1.129	1153.7
20	0.62	0.322	0.365	0.473	0.523	0.743	0.807	0.923	0.897	972.4
21	0.74	0.329	0.360	0.352	0.472	0.671	0.803	0.865	0.885	1163.6
23	0.72	0.255	0.376	0.433	0.474	0.751	0.843	0.965	1.011	1235.5
24	0.70	0.203	0.312	0.432	0.519	0.760	0.903	0.940	0.952	1214.5
25	0.71	0.232	0.309	0.391	0.398	0.656	0.888	0.839	0.956	1288.9
26	0.74	0.108	0.378	0.343	0.428	0.652	0.825	0.780	0.945	1282.4
28	0.68	0.439	0.511	0.570	0.711	0.980	1.141	1.115	1.104	932.6
29	0.74	0.258	0.356	0.528	0.659	0.938	1.126	1.160	1.154	920.3
30	0.69	0.333	0.436	0.456	0.673	0.849	1.007	1.042	1.038	878.8
31	0.69	0.378	0.460	0.498	0.785	0.874	1.029	0.986	1.005	773.8
34	0.81	0.417	0.453	0.449	0.540	0.866	0.945	1.021	0.994	824.0
Av.	0.71	0.280	0.398	0.488	0.601	0.869	0.971	1.041	1.046	975.4
G. M.	0.47	0.274	0.370	0.470	0.615	0.861	0.950	0.992	1.009	

Op.: operator number, **r^2 :** coefficient of determination, **Pi:** initial performance, **P50:** average performance at 50 PWH, **P100:** average performance at 100 PWH, **P200:** average performance at 200 PWH, **P500:** average performance at 500 PWH, **P750:** average performance at 750 PWH, **P1000:** average performance at 1000 PWH, **Pf:** stabilized performance (final), **hrs.:** number of PWH to reach stable performance, **Av.:** average for each parameter, **G.M.:** General Model.

Table 3 shows summarized performances at different moments of the learning progress for each studied operator, r^2 of each individual model and number of hours needed to reach stable performance. r^2 values for the general model,

showed a coefficient of 0.47 which is high considering that all the operator effects are included for this model. When assessing at individual models, r^2 values are higher (average of 0.71) as it would be expected. The average number of hours needed to achieve the stable performance is 975.4 PWH with a standard deviation of 205.5. Expressed otherwise, regarding this study, the end of the learning curve corresponds to an average of 142 days (around 6.5 months) or 10,007 m³ processed wood. The average Initial performance is 28% of the expected potential, showing at 100 APWH an average of 49% of its potential; similar results were also observed by applying the general model.

2.4.3. Correlations

Correlation of measured productivity, between all learning process phases and final performance of each individual operator, are presented (Table 4). It shows, when assessing first stages from 100 APWH and further, performances are already highly correlated (coefficients above 0.83) with final performance, those values presented high values of significance (p value < 0.01).

Table 4. Correlation coefficients between performances at different initial stages and at the end of the learning period on the left side of the table, p -values for each coefficient on the right side of the table

	Pi	P50	P100	P150	P200	Pf
Pi	1.00	4.5 E ⁻⁵	0.01	3.4 E ⁻³	0.01	0.01
P50	0.71	1.00	5.4 E ⁻⁷	3.8 E ⁻⁶	1.1 E ⁻⁵	1,0 E ⁻⁴
P100	0.50	0.81	1.00	3.0 E ⁻¹²	9.4 E ⁻¹⁰	8.9 E ⁻⁹
P150	0.55	0.77	0.93	1.00	0.1 E ⁻¹²	1.5 E ⁻⁹
P200	0.49	0.75	0.89	0.96	1.00	1.5 E ⁻⁷
Pf	0.50	0.69	0.87	0.89	0.83	1.00

Pi (initial performance level), **P50** (50 APWH performance level), **P100** (100 APWH performance level), **P150** (150 APWH performance level), **P200** (200 APWH performance level) and **Pf** (final performance level)

Principal Component Analysis (Figure 6) is designed to visualize the

association between initial learning phases performances with final performance and in turn how operators are ordered. It shows the operators distribution by their performance: on the right side are located those with higher performance values and on the left side are those with lower performances values during learning process. In addition, concerning performances during initial times, is possible to state that individual performances at 100 APWH and further were positively and strongly associated with its final performance; while initial performance and at 50 APWH were positively associated but not as strongly. Hence, outstanding operators at initial phases are highly probable to have higher potential, in terms of productivity (m^3/PWH), when its learning is fulfilled.

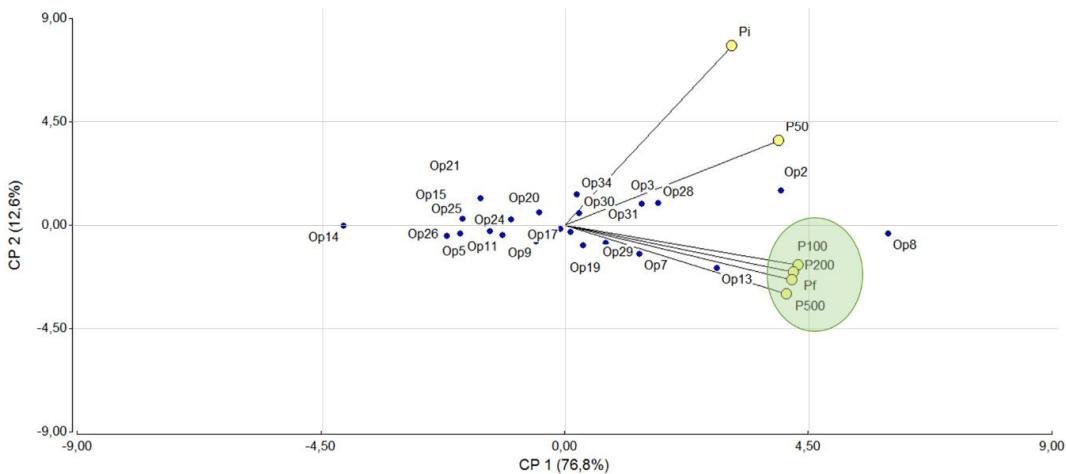


Figure 6. Biplot of performances among different initial time periods and when stabilized (final performance). **Op** (operator's distribution regarding matching performances during learning), **Pi** (initial performance level), **P50** (50 APWH performance level), **P100** (100 APWH performance level), **P150** (150 APWH performance level), **P200** (200 APWH performance level) and **Pf** (final performance level)

2.5. DISCUSSION

The described general model explains the learning development until an operator reaches stable productivity; operator being without previous experience and

learning process including 50 hours in simulator and theoretical instructions. Since this curve was done in relative terms of productivity, any company with the knowledge of potential productivity regarding their own scenarios, will be able to plan and estimate the wood flows when they are facing training process of new operators.

The learning process can be described as the following:

- (1) An operator recognizes and memorizes the movements of the commands and keyboard controls while operating. At this phase productivity should have increasing increments (Parker et al., 1996).
- (2) After being familiarized with controls, by repetitions, the operator starts automatizing the movements, increasing coordination skills, e.g doing several movements at one time. Automatic mode and multitasking starts (Purfürst, 2010).
- (3) Operator makes fewer mistakes, understands how a tree reacts and anticipates future movements looking for efficiency along every stage of the process.

When carrying out individual models, the first phase of the learning process defined above, is just visualized for scattered operators. Nevertheless, the majority of them did not show this phase. Probably due to all the observations have been taken when operators had already started working in the machine and not when they were at the simulator, hence they mostly have already learned and were familiar with the crane and harvester head controls. This could be a reason why this model happen to be monomolecular and not logistic as explained by other authors (Parker

et al., 1996; Purfürst, 2010).

The time frame needed for an operator to finish its learning, showed to be shorter than the figures presented by Purfürst (2010). It can be stated, that in pulp wood production studied scenario, when harvesting single assortment, using clear-cut as harvesting method and homogeneous forests (monoculture and even aged), operators might have faster learning. Therefore, the more homogeneous and standardized is the production, the shorter learning time is needed to reach potential performance.

On the other hand, this study was done with relatively newer harvesters in comparison with other studies. The machines are continuously updated, enhanced and technology is improved, resulting in more intuitive commands, which makes it easier for new operators to develop control of the machine. Furthermore, as new development and researches are still being carried out by manufacture companies towards automatization in control systems, it can be expected faster learning periods for future operators at the phases 1 and 2 described above.

In this study, the learning curve was assessed for just one type of cut to length system machine, therefore forwarder machines should be also addressed for the same purpose in order to count overall information of the logging system (harvester-forwarder). Using StanForD files from OBC, showed to be accurate and suitable when addressing productivity models of logging operations, especially at very standardized productions such us for pulp purposes. Hence, the methodology employed within this study can be also emulated for further productivity assessments as long as calibrations are performed regularly.

Another important finding is the possibility of recognizing higher productive operators already at early stages of the learning process. But due to the fact, that already at 100 PWH operators present a significant cost for any company, it is important to select skilled operators even sooner when possible. As subjective evaluations at the simulator phase did not corresponded with the same criteria for all studied operators, it was not possible to measure associations with final performance. Therefore, additional studies to identify skilled operators are needed; requiring the design of evaluation tools and/or methodologies at simulator phase of the learning process.

Nevertheless, according to Häggström (2015) productivity is a system composed by three main parts: human (skills and abilities), technology (tools and prostheses) and the organization (culture and structure of the company). Therefore, to select operators just by their abilities to drive a machine must not be taken as an isolated criterion. Each company has its own structure, resources, ways to motivate teams, among other factors, that must be put into consideration. Hence, in order to accomplish an appropriate selection, behavioural profiles studies, customized by organization types, must be also included (Pagnussat & Lopes 2017).

2.6. CONCLUSIONS

A period of approximately six and a half months (975,4 PWH with a standard deviation of 205,5), depending on the shift schedules of each company, is needed for an operator to reach a stable productivity. The productivity of an operator during their learning period is represented by a monomolecular model which becomes asymptotic when the learning is finished; hence, the operator can still slightly

increase its productivity during some time. This study, gives forest logging companies information to make suitable plans of the wood flows during periods of training new operators in the organization.

It is possible to encounter skillful and productive operators at around 100 PWH of the learning process; although behavioral profiles, regarding company's culture and work organization, must be consider in order to be complemented with previous statement. The outcome could enhance overall harvesting production, either while building new harvesting teams or when replacing operators.

2.7. ACKNOWLEDGMENTS:

This work has been done within the post grade program framework of the Universidad de la República, Faculty of Agronomy in order to accomplish the title of Master in Sciences and in collaboration with the companies: Montes del Plata, Lignum and Phelox.

Author Contributions: Gonzalo García designed the methodology, did most of the data-analysis, wrote the paper and guided manuscript writing and editing; Gustavo A. Daniluk gave ideas for the study, contributed to the discussion sections, and conceived the experiment; María V. Gravina contributed to the methodology, contributed to the discussion of this study and conceived the experiment.

Conflicts of Interest: The authors declare no conflict of interest.

2.8. REFERENCES

Akay AE, Erdas O, Sessions J. 2004. Determining Productivity of Mechanized

Harvesting Machines. *J Appl Sci.* 4:100–105.

Arlinger J, Bergek S, Hult L, Larsson-Snygg B, Morenius B, Sondell J. 2012.

Operational monitoring of forest machines under working condition - Definitions and implementations of time concepts and repair causes within the StanForD framework - Version 3.0. Sweden: Skogfork.

- Björheden R, Thompson M. 1995. An international nomenclature for forest work study. In IUFRO 1995 20th World Congress. Subject Area S3.04, Tampere, Finland. Proceedings. p. 190-215.
- Bramucci M, Seixas F. 2002. Quantification and determination of influence factors over harvesters productivity. *Sci For.* 62:62–74.
- Brunberg T, Thelin A, Westerling S. 1989. Basic data for productivity standards for single-grip harvesters in thinning. The Forest Operations Institute of Sweden. 3:25.
- Calabrese D. 2000. Canadian Switches to Mechanized, Cut- to-Length. TimberLine. [accesed 2018 oct 22]:[4 p].
<http://www.timberlinemag.com/articledatabase/view.asp?articleID=222>
- Chen P, Popovich P. 2002. Correlation: Parametric and Non Parametric Measures. Series: Quantitative Applications in the Social Sciences. Thousand Oaks: Sage. [104 p].
- Crawley MJ. 2013. The R book. 2nd ed. A John Wiley & Sons Publication. Imperial College London at Silwood Park, UK.
- Da Silva E. 2012. Technical and economic evaluation of a “harvester” in eucalyptus timber cutting. [Magister Scientiae Dissertation], Viçosa Minas Gerais – Brazil: Universidade Federal de Viçosa.
- Di Renzo JA, Casanoves F, Balzarini MG, Gonzalez L, Tablada M, Robledo CW. 2016. InfoStat version 2016. InfoStat Group, FCA. Universidad Nacional de Córdoba, Argentina.
- FAO. 2001. Improving forest harvesting practices through training and education. [accesed 2017 dec 10].
<http://www.fao.org/docrep/005/AC805E/ac805e0c.htm>
- Gellerstedt S. 2002. Operation of the single-grip harvester: motor-sensory and cognitive work. *IJFE.* 13:35–47.
- Gellerstedt S, Liden E, Bohlin F. 2005. Health and performance in mechanised forest operations. Swedish University of Agricultural Sciences. [accesed

- 2018 jun 22]. www2.spm.slu.se/ergowood
- González V, Tolosana E, Ambrosio Y, Laína R, Vignote S. 2014. Manual de mecanización de los aprovechamientos forestales [Forest logging mechanization handbook]. Madrid. MundiPrensa. Spanish
- Häggström C. 2015. Human Factors in Mechanized Cut-to-Length Forest Operations. [Doctoral Dissertation]. Umea, Sweden: Swedish University of Agricultural Sciences.
- Holtzcher M, Lanford B. 1997. Tree Diameter Effects on Cost and Productivity of cut-to-length Systems. FPJ. 47:25–30.
- Kärhä K, Rönkkö E, Gumse S. 2004. Productivity and Cutting Costs of Thinning Harvesters. IJFE. 15:43–56.
- Kirk PM, Byers JS, Parker RJ, Sullman MJ. 1997. Mechanisation Developments Within the New Zealand Forest Industry: The Human Factors. IJFE. 8:75–80.
- Linhares M, Sette Júnior CR, Campos F, Yamaji FM. 2012. Eficiência e desempenho operacional de máquinas harvester e forwarder na colheita florestal [Harvester and Forwarder machines efficiency and operational performance in forest harvesting]. Pesquisa Agropecuária Tropical. 42:212–219. Portuguese.
- Lorenzo J. 2010. Mecanización de la cosecha; eficiencia, rentabilidad y seguridad [Mechanization at logging operations; efficiency, profitability and safety]. Montevideo, Uruguay: Guia Forestal. [Accessed 2015 Nov 20] <http://guiaforestal.com>. Spanish
- Malinovski RA, Malinovski JR. 1998. Evolução dos sistemas de colheita de povoamentos de pinus na Região Sul do Brasil [Evolution of two logging systems with pinus stands from south Brasil region]. Curitiba: FUPEF do Paraná. Portuguese
- [MGAP DGF] Ministerio Ganaderia Agricultura Pesca, Direccion General Forestal. 2018. Estadísticas Forestales 2018 [Forest Statistics]. [accesed 2018]

nov 5].

http://www.mgap.gub.uy/sites/default/files/dgf_boletin_estadistico_2018_0.pdf. Spanish

Nurminen T, Korpunen H, Uusitalo J. 2006. Time Consumption Analysis of the Mechanized Cut-to-length Harvesting System. *SILVA FENN.* 40:335–363.

Olivera A, Visser R, Acuna M, Morgenroth J. 2016. Automatic GNSS-enabled harvester data collection as a tool to evaluate factors affecting harvester productivity in a *Eucalyptus* spp. harvesting operation in Uruguay. *IJFE*. 27:15–28.

Ovaskainen H. 2005. Comparison of harvester work in forest and simulator environments. *SILVA FENN.* 39:89–101.

Pagnussat MB, Lopes ES. 2017. The Behavioral Profile of harvester operators. *Revista Árvore*. 41:1–7.

Parise DJ. 2005. Influência Dos Requisitos Pessoais Especiais No Desempenho De Operadores De Máquinas De Colheita Florestal De Alta Performance [Personal requirements influence on forest logging machines performances]. [Magister Scientiae Dissertation], Curitiba - Brazil: Universidade Federal do Panamá. Portuguese.

Parker R., Kirk P, Sullman M. 1996. Learning curves of mechanised harvester and Forwarder Operators. *Logging Industry Research Organisation*. 21.

Parra M, Carey P. 2000. Consideraciones metodológicas para la evaluación de la cortadora-procesadora (harvester) en operaciones forestales [Methodological considerations when assessing a harvester during logging operations]. *Bosque*. 21:137–146. Spanish.

Purfürst FT. 2010. Learning curves of harvester operators. *Croatian Journal of Forest Engineering*, 31:89-97.

Purfürst FT, Erler J. 2011. The Human Influence on Productivity in Harvester Operations. *IJFE*. 22:15–22.

Purfürst T, Lindroos O. 2011. The correlation between long-term productivity and

short-term performance ratings of harvester operators. CROAT J FOR ENG. 32:509-519

Ranta P. 2004. Possibilities to develop forest machine simulator based education with Technology. Proceedings of Development Project in Forest Machine Based Training (ProForSim). Joensuu, Finland.

Ranta P. 2009. Added values of forestry machine simulator based training. Proceedings of the 5th International conference on multimedia and ICT in education, April 22-24. Linsbon, Portugal.

Simões D, Fenner PT, Tsutsui MS, Resumo E. 2010. Avaliação técnica e econômica da colheita de florestas de Eucalipto com harvester [Technical and economic assessment of forest logging in Eucalyptus using harvester]. Sci For. 38:611–618. Portuguese.

Skogforsk. 2015. StanForD. [accesed 2018 feb 1].
<http://www.skogforsk.se/english/projects/stanford>

Stampfer K, Steinmüller T. 2001. A New Approach To Derive A Productivity Model for the Harvester ‘Valmet 911 Snake’. Proceedings of the international mountain logging and 11th Pacific Northwest Skyline symposium - A forest engineering odyssey. December 10-12. Seattle, Washington, DC, University of Washington and IUFRO. p 254-262.

Strandgard M, Walsh D, Acuna M. 2013. Estimating harvester productivity in Pinus radiata plantations using StanForD stem files. SCAND J FOREST RES. 28:73–80.

Tolosana E, González G, Vignote S. 2004. El aprovechamiento maderero [Forest logging]. Madrid, Spain: Mundi-Prensa. Spanish.

Torrijos YA, Tolosana EE. 2016. El control de tiempos y rendimientos en los trabajos forestales [Time study and productivity in forest works]. El programa Kronos. Montes. 87:14–20.Spanish.

UPM and the Government of Uruguay sign an investment agreement to establish a competitive operating platform for a possible new pulp mill in Uruguay.

(2017). [Accessed 2018 Jan 28]. <http://www.upm.com/About-us/Newsroom/Releases/Pages/UPM-and-the-Government-of-Uruguay-sign-an-investment-agreement-to-establish-a-co-001-Wed-08-Nov-2017-00-18.aspx>

Uruguay XXI. Oportunidades de Inversión, Sector Forestal [Investment Opportunities, Forest Sector]. 2017. [Accessed 2018 Feb 22]. <http://www.uruguayxxi.gub.uy/informacion/content/uploads/sites/9/2017/09/Sector-Forestal-Setiembre-2017.pdf>. Spanish.

Uusitalo J, Pearson M. 2010. Introduction to forest operations and technology. JVP forest systems Oy, 287 p.

Väätäinen K, Sikanen L, Asikainen A. 2004. Feasibility of Excavator-Based Harvester in Thinnings of Peatland Forests. IJFE. 15:103-111.

Volodina A, Nagy G, Köller O. 2015. Success in the first phase of the vocational career: The role of cognitive and scholastic abilities, personality factors, and vocational interests. J Vocat Behav. 91:11–22.

Wagner T. 2004. From the eighties up to the future - the development of forest machine simulators - A story of succes ?. Proceedings of Simulator-Based Training of forest machine operators. Joensuu, Finland.

Westerberg S, Shiriaev A. 2013. Virtual Environment-Based Teleoperation of Forestry Machines: Designing Future Interaction Methods. J Hum Robot Interact. 2:84–110.

3. RESULTADOS Y DISCUSIÓN GENERAL

3.1. RESULTADOS

Se obtuvo un modelo general con las observaciones de 25 operadores durante todos sus procesos de aprendizaje. El modelo que mejor se ajustó corresponde a un modelo monomolecular, lo que significa que la productividad de un operador comienza en el punto más bajo y va aumentando con incrementos decreciente en el tiempo, volviéndose la curva asintótica. Algunos autores (Parker et al. 1996 y Purfürst 2010) explican la curva de aprendizaje como un modelo logístico, con una fase inicial de incrementos crecientes y que posteriormente cambia a incrementos decrecientes, también convirtiéndose asintótica en la fase final. Esta evolución se dio para algunos de los operadores involucrados en este estudio. El proceso de aprendizaje de un operador de harvester puede ser descrito de la siguiente manera:

- (1) El operador reconoce y memoriza los movimientos de los comandos y controles de teclado durante la operación. En esta fase la productividad tiene incrementos cada vez mayores (Parker et al., 1996)
- (2) Luego de estar familiarizado con los controles, por repeticiones el operador comienza a automatizar los movimientos e incrementar las habilidades de coordinación; por ejemplo, haciendo varios movimientos al mismo tiempo. En esta fase los incrementos en productividad ya son decrecientes (Purfürst, 2010)
- (3) El operador comete menos errores, entiende cómo el árbol reaccionará y anticipa los movimientos futuros en busca de la eficiencia en cada proceso.

La primera fase se visualiza solo para algunos modelos individuales, pero no en el modelo general. La razón que podría explicar este comportamiento es que todas las observaciones han sido tomadas cuando los operadores ya se encontraban trabajando en la máquina y no en el simulador, por lo tanto, ya habrían aprendido o estaban familiarizados con los controles grúa y cabezal. Incluso en aquellos operadores que mostraron curvas individuales de aprendizaje como logística, esta

fase inicial fue muy corta y la curva se presentó con incrementos decrecientes luego de pocas horas de trabajo.

La curva de aprendizaje (Figura 2) está representada por la evolución de la productividad relativa de los operadores en función de las horas productivas de trabajo acumuladas (APWH). La ecuación resultante con mejor ajuste para describir la evolución de la productividad durante el aprendizaje fue:

$$P_R = [1,030 * (1 - 0,734 * e^{(-0,003 \times APWH)})]$$

Donde, P_R es la productividad relativa y APWH (hrs) son las horas productivas acumuladas de trabajo.

En el modelo general, fue posible observar que el desempeño de los operadores en el momento inicial (cuando empiezan a trabajar directamente en el harvester) se situó en el 28% del potencial. A su vez, resultó que 975,4 horas productivas de trabajo (PWH) son necesarias, en promedio, para alcanzar el potencial de un operador o bien que su productividad se estabilice; mostrando alta variabilidad entre los operadores, cuya desviación estándar fue de 205,5. Este valor expresado en tiempo calendario correspondería a aproximadamente 6,5 meses (dependiendo de la organización de turnos de la empresa). El incremento promedio en términos relativos de la productividad fue de 0,08% por cada PWH y las tasas más altas se dieron al comienzo, donde un operador alcanzaría un 50% de la productividad potencial luego de 100 PWH (aumento del rendimiento en este momento correspondiente a 0,21% por cada PWH).

A través de una regresión lineal entre los valores predichos del modelo y las observaciones (Figura 3) se obtuvo un coeficiente de determinación (r^2) de 0,469, que representa el porcentaje de la variabilidad explicado por el modelo obtenido. La distribución de los residuales presentó una distribución normal (Figura 4). En ambos gráficos (Figuras 3 y 4), se observa una acumulación de observaciones al

final, sobre el valor absoluto 1, lo cual, por estar trabajando con productividades relativas, comprueba que los modelos locales de productividad utilizados se ajustan a los escenarios de cosecha estudiados.

Como se observa en la Tabla 4, ya a partir de 100 PWH los valores de productividad están altamente correlacionados con la productividad final de los operadores. En este momento de evaluación, se presentó un coeficiente de correlación (r) de 0,87, con un nivel de significancia menor a 0,01. En posteriores momentos de evaluación (P150, P200, etc.) estos coeficientes de correlación mostraron valores por encima de 0,83 y mantuvieron niveles de significancia alta (valor p menores a 0,01).

3.2. DISCUSIÓN

El modelo general nos explica cuántas horas productivas de trabajo son necesarias para que un operador de harvester alcance una productividad estable o su potencial. A su vez, la forma de la curva explica el desarrollo de la productividad de este operador durante el proceso de aprendizaje. Por otra parte, como el estudio de esta curva se ha hecho en términos de productividad relativa, cualquier empresa con el conocimiento de la productividad potencial de sus bosques a cosechar, serán capaces de planificar y estimar los flujos de madera cuando tienen los operadores en proceso de formación.

El tiempo necesario para que un operador termine su aprendizaje, demostró para este estudio ser menor que en estudios realizados anteriormente como Purfürst (2010) y Parker et al. (1996). Se podría destacar, para el escenario de producción de madera para pulpa en Uruguay, la cosecha es realizada con un único producto y en tala rasa debería representar menos dificultades para nuevos operadores. Por lo tanto, al ser el trabajo más homogéneo y estandarizado, el tiempo necesario para alcanzar el rendimiento potencial es menor. Complementariamente, este estudio se ha realizado con máquinas más nuevas en comparación con otros estudios (Purfürst 2010 y Parker et al. 1997). Las mismas han incorporado mayor desarrollo y

mejoraron su tecnología, resultando en comandos más intuitivos que también hacen más fácil para los nuevos operadores aprender el manejo total de la máquina. A su vez, las empresas fabricantes de maquinaria invierten en investigación y nuevos desarrollos en forma continua, tendiendo hacia ciertas automatizaciones de los sistemas de control en algunas fases del procesado del árbol. Esto se debería traducir en periodos de aprendizaje más rápidos para futuras generaciones de maquinaria. El acortamiento del proceso es esperable que se vea más reflejado en las fases de aprendizaje 1 y 2 descriptas.

En este estudio, la curva de aprendizaje fue evaluada para solo un tipo de maquinaria de la línea “*Cut to length*”; por lo tanto, el aprendizaje en Forwarders también es un aspecto que debe ser estudiado y evaluado para poder contar con toda la información completa del sistema de cosecha.

Como también fue demostrado en el estudio de Olivera et al. (2016), el uso de los archivos bajo lineamientos StanForD de las computadoras de abordo de las máquinas forestales, se mostraron ser precisas y ajustadas para el caso de estudio de modelos que involucren productividad de la maquinaria, sobre todo cuando son sistemas de producción estandarizados como el caso de la producción para pulpa de celulosa. Por lo tanto, la metodología utilizada en este estudio puede ser utilizada en futuras investigaciones

Otro hallazgo es la posibilidad de reconocer a los operadores destacados ya en las primeras etapas del proceso de aprendizaje. Debido al hecho que luego de 100 PWH el operador que está aprendiendo ya representaba un costo significativo para una empresa, es importante seleccionar los mejores operadores tan pronto como sea posible. Por lo tanto, pruebas de selección de los mejores operadores ya en el nivel de simulador debería ser diseñada y evaluada a futuro para tal propósito.

Por otra parte, como fue mencionado en el estudio de Häggström (2015), la productividad es un sistema compuesto por tres partes principales: la parte humana (destrezas y habilidades del operador), la tecnológica (máquinas y los elementos

disponibles para la realización del trabajo) y la organización (tipo de estructura y cultura de la empresa). Por lo tanto, en la selección de operadores, no puede ser tomado de forma aislada solamente sus habilidades, sino que deben ser incluidos los demás factores que componen el sistema. En este contexto, tiene sentido lo descripto por Pagnussat y Lopes (2017) que señalan que la evaluación de perfiles de comportamiento de los operadores también es importante ser considerado, pero debería estar ajustado al tipo de organización donde se esté seleccionando los operadores.

4. CONCLUSIONES

Un periodo de tiempo de aproximadamente 6 meses y medio, dependiendo de la organización de turnos de la empresa, son necesarios para que un operador alcance una productividad estable cuando está en un proceso de aprendizaje de manejo de maquinaria forestal de cosecha.

La evolución de la productividad de un operador durante su aprendizaje fue representada por una curva monomolecular, que se vuelve asintótica al finalizar el mismo; por lo tanto, el operador podría aún, a tasas muy bajas, seguir aumentando su productividad por cierto tiempo.

El conocimiento de esta curva de aprendizaje permite a las empresas forestales realizar una planificación y flujos de madera a cosechar más exacta cuando pasan por periodos con nuevos operadores, como también para tener una estimación más exacta del presupuesto necesario para formar operadores.

Es necesario que las compañías realicen procesos de selección incorporando evaluaciones de perfil del comportamiento, ajustado a sus organizaciones; lo cual podría ser complementado a través de selección de operadores con mejores habilidades operativas en etapas tempranas. De esta forma, las empresas podrían mejorar la producción global en toda la organización o bien ser implementado cuando estas deben pasar por la formación de nuevos equipos de trabajo.

5. BIBLIOGRAFÍA

- Akay AE, Erdas O, Sessions J. 2004. Determining Productivity of Mechanized Harvesting Machines. *Journal of Applied Sciences*. 4:100–105.
- Arlinger J, Bergek S, Hult L, Larsson-Snygg B, Morenius B, Sondell J. 2012. Operational monitoring of forest machines under working condition - Definitions and implementations of time concepts and repair causes within the StanForD framework - Version 3.0. Suecia: Skogforsk.
- Björheden R, Thompson M. 1995. An international nomenclature for forest work study. En IUFRO 1995 20th World Congress. Subject Area S3.04, Tampere, Finlandia. Proceedings. p. 190-215.
- Bramucci M, Seixas F. 2002. Quantification and determination of influence factors over harvesters productivity. *Scientia Forestalis*. 62:62–74.
- Brunberg T, Thelin A, Westerling S. 1989. Basic data for productivity standards for single-grip harvesters in thinning. The Forest Operations Institute of Sweden. 3:25.
- Burla ER. 2008. Technical and economic evaluation of a “harvester” in Eucalyptus timber cutting. *Disertación Magister en Ciencias*. Viçosa Minas Merais – Brasil: Universidade Federal de Viçosa. 62 p. Consultado 8 julio 2018. Disponible en: <http://www.ipef.br/servicos/teses/arquivos/burla,er.pdf>
- Calabrese D. 2000. Canadian Switches to Mechanized, Cut- to-Length. TimberLine (Publicación en línea). Consultado 22 octubre 2018. Disponible en: <http://www.timberlinemag.com/articledatabase/view.asp?articleID=222>.
- Chen P, Popovich P. 2002. Correlation: Parametric and Non Parametric Measures. Sage University Papers Series on Quantitative Applications in the Social Sciences. 104 p.
- Crawley MJ. 2013. The R book. 2da edición. A John Wiley & Sons Publication. Imperial College London at Silwood Park, UK.
- Daniluk G. 2002. Código de Cosecha Forestal Uruguayo (publicación en línea).

- Montevideo, Facultad de Agronomía. 90 p. Consultado 10 jun. 2018.
Disponible en <http://www.fagro.edu.uy/~forestal/index.html>
- Da Silva E. 2012. Technical and economic evaluation of a “harvester” in eucalyptus timber cutting. Disertación Magister en Ciencias. Viçosa Minas Merais – Brazil: Universidade Federal de Viçosa. 129 p.
- Di Rienzo JA, Casanoves F, Balzarini MG, Gonzalez L, Tablada M, Robledo CW. 2016. InfoStat versión 2016. Grupo InfoStat, FCA, Universidad Nacional de Córdoba, Argentina.
- FAO. 2001. Improving forest harvesting practices through training and education. Consultado 10 diciembre 2017. Disponible en:
<http://www.fao.org/docrep/005/AC805E/ac805e0c.htm>
- Gellerstedt S, Liden E, Bohlin F. 2005. Health and performance in mechanised forest operations. Swedish University of Agricultural Sciences. Consultado 22 junio 2018. Disponible en: www2.spm.slu.se/ergowood
- Gellerstedt S. 2002. Operation of the single-grip harvester: motor-sensory and cognitive work. International Journal of Forest Engineering, 13:35–47.
- González V, Tolosana E, Ambrosio Y, Laína R, Vignote S. 2014. Manual de mecanización de los aprovechamientos forestales. Madrid. MundiPrensa.
- Häggström C. 2015. Human Factors in Mechanized Cut-to-Length Forest Operations. Disertación Doctoral. Umea, Suecia: Swedish University of Agricultural Sciences. 77 p.
- Holtzcher M, Lanford B. 1997. Tree Diameter Effects on Cost and Productivity of cut-to-length Systems. Forest Products Journal. 47:25–30.
- Ibarra M, Rodriguez M. 2010. Cosecha forestal altamente mecanizada. [Tesis de grado Ingeniero Agrónomo]. Montevideo, Uruguay: Universidad de la Republica. 77 p.
- Kärhä K, Rönkkö E, Gumse S. 2004. Productivity and Cutting Costs of Thinning Harvesters. International Journal of Forest Engineering. 15:43–56.

- Kirk PM, Byers JS, Parker RJ, Sullman MJ. 1997. Mechanisation Developments Within the New Zealand Forest Industry: The Human Factors. International Journal of Forest Engineering. 8:75–80.
- Linhares M, Sette Júnior CR, Campos F, Yamaji FM. 2012. Eficiência e desempenho operacional de máquinas harvester e forwarder na colheita florestal. Pesquisa Agropecuária Tropical. 42:212–219.
- Lorenzo J. 2010. Mecanización de la cosecha; eficiencia, rentabilidad y seguridad. Montevideo, Uruguay: Guia Forestal. Consultado 20 noviembre 2015.
Disponible en: <http://guiaforestal.com>
- Magalhaes P, Katz I. 2010. Estudo da viabilidade econômica da mecanização do processo de colheita florestal com harvester em uma indústria madeireira. Tékhne Lógos, Botucatu, SP, v. 2, n. 1, p. 72- 91.
- Malinovski RA, Malinovski JR. 1998. Evolução dos sistemas de colheita de povoamentos de pinus na Região Sul do Brasil. Curitiba: FUPEF do Paraná.
- MGAP-DGF (Ministerio Ganaderia Agricultura Pesca, Dirección General Forestal). 2018. Estadísticas Forestales 2018. Consultado 5 noviembre 2018.
Disponible en:
http://www.mgap.gub.uy/sites/default/files/dgf_boletin_estadistico_2018_0.pdf
- Nurminen T, Korppunen H, Uusitalo J. 2006. Time Consumption Analysis of the Mechanized Cut-to-length Harvesting System. Silva Fennica 40:335–363.
- Olivera A, Visser R, Acuna M, Morgenroth J. 2016. Automatic GNSS-enabled harvester data collection as a tool to evaluate factors affecting harvester productivity in a *Eucalyptus* spp. harvesting operation in Uruguay. International Journal of Forest Engineering. 27:15–28.
- Ovaskainen H. 2005. Comparison of harvester work in forest and simulator environments. Silva Fennica. 39:89–101.
- Pagnussat MB, Lopes ES. 2017. The Behavioral Profile of harvester operators. Revista Árvore. 41:1–7.

- Parise DJ. 2005. Influência Dos Requisitos Pessoais Especiais No Desempenho De Operadores De Máquinas De Colheita Florestal De Alta Performance. Disertación Magister en Ciencias, Curitiba - Brasil: Universidade Federal do Parana. 159 p.
- Parker R., Kirk P, Sullman M. 1996. Learning curves of mechanised harvester and Forwarder Operators. Logging Industry Research Organisation Report 21(29): 1–6.
- Parra M, Carey P. 2000. Consideraciones metodológicas para la evaluación de la cortadora-procesadora (harvester) en operaciones forestales. Bosque. 21:137–146.
- Pino P, Ponce M, Aviles C, Vallejos O. 2015. Productivity improvement in a sawnwood mill using salary incentive. Maderas, Cienc. tecnol. Vol.17, n.1, pp.117-128.
- Purfürst T, Lindroos O. 2011. The correlation between long-term productivity and short-term performance ratings of harvester operators. Croatian Journal of Forest Engineering. 32:509-519
- Purfürst FT. 2010. Learning curves of harvester operators. Croatian Journal of Forest Engineering, 31:89-97.
- Purfürst FT, Erler J. 2011. The Human Influence on Productivity in Harvester Operations. International Journal of Forest Engineering. 22:15–22.
- Ranta P. 2004. Possibilities to develop forest machine simulator based education with Technology. Proceedings of Development Project in Forest Machine Based Training (ProForSim). Joensuu, Finland.
- Ranta P. 2009. Added values of forestry machine simulator based training. Proceedings of the 5th International conference on multimedia and ICT in education, April 22-24. Linsbon, Portugal.
- Rivas F, Suárez R. 2014. Estudios de Tiempos y Evaluación de Rendimiento de Maquinaria de Cosecha Forestal. [Tesis de grado Ingeniero Agrónomo]. Montevideo, Uruguay: Universidad de la Republica.

- Simões D, Fenner PT, Tsutsui MS, Resumo E. 2010. Avaliação técnica e econômica da colheita de florestas de eucalipto com harvester. *Scientia Forestalis*. 38:611–618.
- Skogforsk. 2015. StanForD. Consultado 1 debrero 2018. Disponible en:
<http://www.skogforsk.se/english/projects/stanford>
- Stampfer K, Steinmüller T. 2001. A New Approach To Derive A Productivity Model for the Harvester ‘Valmet 911 Snake’. Proceedings of the international mountain logging and 11th Pacific Northwest Skyline symposium - A forest engineering odyssey. Diciembre 10-12. Seattle, Washington, DC, University of Washington y IUFRO. p 254-262.
- Strandgard M, Walsh D, Acuna M. 2013. Estimating harvester productivity in Pinus radiata plantations using StanForD stem files. *Scandinavian Journal of Forest Research*. 28:73–80.
- Tolosana E, González G, Vignote S. 2004. El aprovechamiento maderero. Madrid, España: Mundi-Prensa.
- Torrijos YA, Tolosana EE. 2016. El control de tiempos y rendimientos en los trabajos forestales . El programa Kronos. *Montes*. 87:14–20.
- UPM and the Government of Uruguay sign an investment agreement to establish a competitive operating platform for a possible new pulp mill in Uruguay. 2017. Consultado 28 enero 2018. Disponible en:
<http://www.upm.com/About-us/Newsroom/Releases/Pages/UPM-and-the-Government-of-Uruguay-sign-an-investment-agreement-to-establish-a-co-001-Wed-08-Nov-2017-00-18.aspx>
- Uruguay XXI. Oportunidades de Inversión, Sector Forestal. 2017. Consultado 22 febrero 2018. Disponible en:
<http://www.uruguayxxi.gub.uy/informacion/content/uploads/sites/9/2017/09/Sector-Forestal-Setiembre-2017.pdf>
- Uusitalo J, Pearson M. 2010. Introduction to forest operations and technology. JVP forest systems Oy, 287 p.

- Väätäinen K, Sikanen L, Asikainen A. 2004. Feasibility of Excavator-Based Harvester in Thinnings of Peatland Forests. International Journal of Forest Engineering. 15:103-111.
- Volodina A, Nagy G, Köller O. 2015. Success in the first phase of the vocational career: The role of cognitive and scholastic abilities, personality factors, and vocational interests. Journal of Vocational Behavior. 91:11–22.
- Wagner T. 2004. From the eighties up to the future - the development of forest machine simulators - A story of succes ?. Proceedings of Simulator-Based Training of forest machine operators. Joensuu, Finland.
- Westerberg S, Shiriaev A. 2013. Virtual Environment-Based Teleoperation of Forestry Machines: Designing Future Interaction Methods. Journal of Human Robot Interaction. 2:84–110.