

المُحدِّدات السلوكية والمسار الزمني للتحوّل من الاستخدام المجاني إلى المدفوع في منتجات البرمجيات كخدمة (SaaS): مقارنة تفسيرية قائمة على التعلّم الآلي

أميرة البحري

أكاديمية ميشيغان للعلوم والتكنولوجيا (الولايات المتحدة الأمريكية).

Behavioural Determinants and the Temporal Pathway of Freemium-to-Paid Conversion in SaaS Products: An Explainable Machine-Learning Approach

Amira Albahri

<https://orcid.org/0009-0003-7613-729X>

Faculty of Graduate Studies, Michigan Academy for Science and Technology, (USA),

amiraelbahri77@gmail.com

تاريخ الاستلام: 2026/07./15 تاريخ القبول: 2026/08./29 تاريخ النشر: 2026/09/01

الملخص:

يهدف هذا البحث إلى تجاوز النظر إلى تحوّل المستخدمين من الاشتراك المجاني إلى المدفوع في منتجات البرمجيات كخدمة (SaaS) بوصفه قراراً لحظياً، وإعادة تأطيره بوصفه مساراً سلوكياً متراكماً قوامه اكتشاف القيمة وتنامي الانخراط. ولتحقيق ذلك، حُلّت بيانات سلوكية فعلية لاستخدام منصّة SaaS لإدارة المشاريع تغطّي 17,024 مستخدماً على مدى اثني عشر شهراً، ضمن إطار منهجية CRISP-DM. ودُرِيت ثلاثة نماذج تعلّم آلي مُشرف—الانحدار اللوجستي والغابة العشوائية وXGBoost—بعد معالجة اختلال توازن الفئات الحاد (بلغت نسبة التحوّل 6.96%) باستخدام تقنية SMOTE والمعاينة التطبيقية وضبط عتبة القرار، وقُيِّمت النماذج بمقاييس الدقّة والاستدعاء ومقياس F1 والمساحة تحت منحنى ROC، ثم فُيِّر أفضلها بقيم SHAP.

وكشفت النتائج أن للمتحوّلين توقيعاً سلوكياً مميزاً يفصلهم عن غيرهم؛ إذ يفوقونهم في مرّات الدخول ومدة الجلسة واتساع استخدام الميزات، وأن التفاعل مع الميزات المدفوعة واتساق الانخراط ونموّه هي أقوى المُحدِّدات. كما تبيّن أن اتجاه الانخراط عبر الزمن مؤشّر حاسم: بلغ معدّل التحوّل لدى ذوي المسار المتزايد 19.4% مقابل 1.8% لذوي المسار المتناقص. وحقّق نموذج XGBoost أفضل أداء ($F1 = 0.526$ ، و $ROC-AUC = 0.804$) بفارقٍ دالٍّ إحصائياً. ويقدم البحث بذلك إطاراً تفسيرياً قابلاً للتطبيق يمكّن فرق المنتج والتسويق من الاستهداف المبكّر المبني على الأدلة بدلاً من التخمين.

الكلمات المفتاحية: التحوّل من المجاني إلى المدفوع؛ تحليلات البرمجيات كخدمة؛ التعلّم الآلي؛ اختلال توازن الفئات؛ الذكاء الاصطناعي القابل للتفسير.

Abstract:

This study reframes freemium-to-paid conversion in Software-as-a-Service (SaaS) products, moving away from treating it as a single moment of decision and toward understanding it as a cumulative behavioural pathway of value discovery and deepening engagement. Drawing on real behavioural usage data from a SaaS project-management platform covering 17,024 users over a twelve-month period, and following the CRISP-DM methodology, three supervised machine-learning models—Logistic Regression, Random Forest, and XGBoost—were trained after addressing severe class imbalance (a 6.96% conversion rate) through SMOTE, stratified sampling, and threshold optimisation. Models were evaluated using precision, recall, F1-score, and the area under the ROC curve, and the strongest model was interpreted using SHAP values.

The results show that converting users carry a distinct behavioural signature: they log in more often, spend longer per session, and explore a wider range of features, with premium-feature interaction, engagement consistency, and engagement growth emerging as the strongest determinants. The trajectory of engagement over time proved decisive—users on an increasing path converted at 19.4% against only 1.8% for those in decline. XGBoost achieved the best performance ($F1 = 0.526$, $ROC-AUC = 0.804$) by a statistically significant margin. The study thus offers an interpretable, actionable framework enabling product and marketing teams to target high-potential users early and on the basis of evidence rather than guesswork.

Keywords: Freemium-to-paid conversion; SaaS analytics; machine learning; class imbalance; explainable AI.

مقدمة:

أصبح النموذج المجاني-المدفوع (Freemium) الاستراتيجية التجارية السائدة في صناعة البرمجيات كخدمة (SaaS)، إذ تُتاح الوظائف الأساسية مجاناً بينما تُوضَع القدرات المتقدمة خلف اشتراك مدفوع، على أمل تحويل جزءٍ من قاعدة المستخدمين الواسعة إلى مشتركين يدفعون. غير أن معدلات التحوُّل تبقى منخفضة على نحوٍ لافت—تتراوح غالباً بين 2% و10%—مما يجعل التنبؤ بالمستخدمين المرشَّحين للترقية مسألةً استراتيجية تمسّ توزيع الإنفاق التسويقي، وتصميم رحلة الاستخدام، وترتيب أولويات تطوير المنتج.

وقد أثبتت الأدبيات أن السلوك هو المفتاح؛ فتواتر الدخول وعمق استخدام الميزات وطول الجلسة وتنوُّع التفاعل كلّها إشاراتٌ ذات دلالة على قرار الدفع (Hamari, Hanner, & Koivisto, 2017). بيد أن أدوات التقارير التقليدية والتقسيم القائم على قواعد تقريبية لم تُصمَّم للتعامل مع البيانات السلوكية عالية الأبعاد والطولية التي تولِّدها المنصَّات الحديثة، في حين يوفر التعلُّم الآلي مقارنةً أنسب لاستخلاص الأنماط التي تسبق التحوُّل مباشرةً من السجَّلات التاريخية. وتزايد في هذا السياق البحوث التي توظّف التعلُّم الآلي والتنقيب في البيانات لبناء نماذج تنبؤية موثوقة في مجالات متعدّدة (Salih, Bashir, & Mosadag, 2026).

إشكالية البحث: رغم غزارة الدراسات التي قارنت خوارزميات التنبؤ، فإن أغلبها تعامل مع التحوُّل بوصفه حدثاً ثنائياً (تحوُّل/لم يتحوُّل) يُنبأ به، دون أن يُفكِّك التوقع السلوكي المميِّز للمتحوِّلين أو يتتبع المسار الزمني الذي يقود إليه. ومن ثمَّ يطرح هذا البحث سؤالاً مختلفاً: ليس فقط «أيُّ نموذجٍ يتنبأ على نحوٍ أفضل؟»، بل «ما السلوكيات التي تميِّز المتحوِّلين، وكيف يتشكَّل التحوُّل عبر الزمن، وكيف نترجم ذلك إلى تدخَّلاتٍ موجَّهة؟».

أسئلة البحث: ينطلق البحث من سؤالٍ رئيسٍ مفاده: ما المُحدِّدات السلوكية والزمنية التي تُميِّز المستخدمين المتحوِّلين من الاستخدام المجاني إلى المدفوع في منتجات البرمجيات كخدمة، وإلى أيِّ مدى يمكن التنبؤ بها؟ ويتفرَّع عنه ثلاثة أسئلة فرعية: (1) هل يمتلك المتحوِّلون توقيعاً سلوكياً قابلاً للقياس يفصلهم عن غيرهم؟ (2) ما أقوى المُحدِّدات السلوكية للتحوُّل، وهل تتفوَّق كيفية الانخراط (اتساقاً ونموّاً) على حجمه المجرد؟ (3) ما علاقة اتجاه الانخراط عبر الزمن (متزايد/مستقر/متناقص) بمعدَّل التحوُّل؟

فرضيات البحث: (1) يمتلك المتحوِّلون توقيعاً سلوكياً قابلاً للقياس يفصلهم عن غيرهم؛ (2) التفاعل مع الميزات المدفوعة واتساق الانخراط ونموّه محدِّدان أقوى من حجم النشاط المجرد؛ (3) اتجاه الانخراط عبر الزمن (متزايد/مستقر/متناقص) مرتبطٌ ارتباطاً وثيقاً بمعدَّل التحوُّل.

أهداف البحث: يسعى البحث إلى (أ) توصيف الفروق السلوكية بين المتحوِّلين وغيرهم وتحديد أقوى محدِّدات التحوُّل؛ (ب) تتبَّع المسار الزمني للانخراط وعلاقته بالتحوُّل؛ (ج) تحويل النتائج القابلة للتفسير إلى إطارٍ عملي للاستهداف والتدخُّل.

الدراسات السابقة:

حظي التنبؤ بتحوُّل المستخدمين في نماذج الاشتراك المجاني-المدفوع باهتمامٍ بحثيٍّ متنامٍ، ويمكن تصنيف الأدبيات ذات الصلة في اتجاهين: دراساتٌ عُنيَت بمحدِّدات التحوُّل السلوكية والتحفيزية، وأخرى عُنيَت بالجوانب المنهجية للتنبؤ بالبيانات غير المتوازنة. ففي الاتجاه الأول، نمذج (Oredo 2025) نية المستخدمين للانتقال من التخزين السحابي المجاني إلى المدفوع باعتماد إطار CRISP-DM ونماذج التعلُّم الآلي، وخلص إلى أثرٍ إيجابيٍّ للمنفعة المدركة واليقظة المعلوماتية، مع بلوغ مقياس F1 نحو 64% وAUC مقدار 0.61، وهي نتائج تُؤكِّد أن قابلية التنبؤ بالتحوُّل قائمةٌ لكنها محدودة السقف.

وفي تجربةٍ ميدانية عشوائية واسعة شملت 680,588 مستخدماً عبر 190 دولة بين عامي 2023 و2024، بيَّن Zhang & Duan (2025) أن إطالة مدَّة التجربة المجانية تزيد التنبؤ والتحوُّل المؤجَّل دون أثرٍ يُذكر على التحوُّل الفوري، مبرِّزين أن التحوُّل عمليةٌ متعدِّدة المراحل لا لحظةً واحدة، وهو ما يتقاطع مع تأطير هذا البحث للتحوُّل بوصفه مساراً متراكماً. وعلى صعيد الدوافع، حلَّ (Sithipolvanichgul et al. 2024) محرِّكات تبني الخدمات المجانية وتحويلها إلى مدفوعة، بينما ربط (Shang et al. 2024) بين تصميم نموذج freemium وأداء المنشأة عبر تحليلٍ نوعيٍّ مقارن قائم على المجموعات الضبابية.

أمَّا الاتجاه الثاني فقد عالَج التحدي المنهجي المركزي المتمثِّل في اختلال توازن الفئات، إذ أظهر (Suguna et al. 2025) أن دمج طرائق التعلُّم التجميعي مع تقنية SMOTE يرفع الدقَّة المتوازنة ومقياس F1 في التنبؤ بالتسرب بصورةٍ دالَّة، بما يتَّسق مع الأسس المنهجية التي يركِّز عليها هذا البحث في معالجة نسبة تحوُّل لا تتجاوز 6.96%. وتطلَّ الأعمال التأسيسية في الغابة العشوائية (Breiman, 2001) و (Chen & Guestrin, 2016) وXGBoost و (Lundberg & Lee, 2017) وSHAP مرجعيَّاتٍ لا غنى عنها لتفسير النماذج.

الفجوة البحثية: يتبيّن ممّا سبق أن معظم الدراسات إمّا اكتفت بالتنبؤ الثنائي (تحوّل/عدم تحوّل) دون تفكيك التوقع السلوكي المميّز للمتحوّلين، أو ركّزت على الجانب المنهجي بمعزل عن المسار الزمني القابل للتفسير والتدخل. ويسدّ هذا البحث تلك الفجوة بالجمع بين توصيف التوقع السلوكي، وتتبع المسار الزمني للانخراط، وترجمة النتائج القابلة للتفسير عبر قيم SHAP إلى إطار تدخل عملي.

منهجية البحث: يعتمد البحث تصميمًا كميًا تطبيقيًا يسير وفق منهجية CRISP-DM، ويحلّل بيانات سلوكية فعلية لـ 17,024 مستخدمًا، ويقارن ثلاثة نماذج تعلّم آلي مُشرّف، ويعالج اختلال توازن الفئات بتقنية SMOTE وضبط العتبة، ثم يفسّر أفضل النماذج بقيم SHAP. وتُعرض في المبحثين التاليين نتائج توصيف التوقع السلوكي أولاً، ثم المسار الزمني وإطار التدخل ثانياً.

المبحث الأول

التوقع السلوكي للمستخدمين المتحوّلين

المطلب الأول: البيانات والمنهجية:

مصدر البيانات: اعتمد البحث على سجلّات نشاط تاريخية لمنصة SaaS لإدارة المشاريع (يُشار إليها حفاظاً على السريّة بـ«المنصة X»)، زوّدها فريق تحليلات البيانات في المنصة، وتغطّي اثني عشر شهراً من يناير إلى ديسمبر 2024. ويلخّص الجدول 1 مواصفات مجموعة البيانات، حيث يبرز التحديّ المنهجي المركزي: لم يتحوّل سوى 6.96% من المستخدمين، وهو ما يمثّل اختلال توازن فئاتٍ حاداً بنسبةٍ تقارب واحداً إلى ثلاثة عشر.

مجتمع الدراسة وعيّنتها: يتكوّن مجتمع الدراسة من جميع مستخدمي المنصة المذكورة خلال فترة الرصد (يناير-ديسمبر 2024). وتمثّل عيّنة الدراسة الحصر الشامل لهذا المجتمع بعد التنظيف، إذ بلغت 17,024 مستخدماً (منهم 1,185 متحوّلاً بنسبة 6.96%). واعتمدت المعاينة الطبقية في تقسيم العيّنة إلى تدريبٍ وتحقّق واختبار بنسبة 70/15/15 مع الحفاظ على نسبة المتحوّلين في كل طبقة، بما يضمن تمثيلاً أميناً للفئة النادرة عبر الأقسام الثلاثة.

الجدول 1: مواصفات مجموعة البيانات السلوكية المستخدمة في الدراسة

العنصر	الوصف
المصدر	منصة SaaS لإدارة المشاريع (مجهولة الهوية)
الفترة الزمنية	يناير - ديسمبر 2024 (12 شهراً)
إجمالي المستخدمين	17,024
المتحوّلون	1,185 (6.96%)
غير المتحوّلين	15,839 (93.04%)
صيغة البيانات	سجلّات CSV وJSON

المصدر: من إعداد الباحثة اعتماداً على نتائج الدراسة، 2026.

المعالجة المسبقة وهندسة الميزات: خضعت البيانات لتنظيفٍ شمل إزالة 123 سجلاً مكرراً، واستبعاد المستخدمين عديدي النشاط، وتصحيح 456 سجلاً متناقض الطوابع الزمنية. وعُولجت القيم المفقودة بحسب دلالتها: بالوسيط للميزات ملتوية التوزيع منخفضة الفقد، وبالصفر لعدد المهام المكتملة على افتراض أن غيابها يعني الإنجاز الصفري. وحُدِّدت القيم الشاذة بقاعدة المدى الرَّبُّيعِي (IQR) ثم قُلِّمت عند المئين التاسع والتسعين للحدِّ من أثرها مع الحفاظ على شكل التوزيع. وأنشئت خمس عشرة ميزةً مشتقةً عبر أربع عائلات (التجميع، والزمنية، والنَّسَب، والنوافذ المتحركة)، ليبلغ الإجمالي أربعين ميزة، اختُزلت بعد إزالة الميزات شديدة الارتباط (فوق 0.8) إلى 37 ميزةً نهائية.

النماذج والتقييم: قُورنت ثلاثة نماذجٍ تمتدَّ من البسيط الشفاف إلى المعقد عالي الأداء: الانحدار اللوجستي (أساسٌ مرجعي)، والغابة العشوائية (Breiman, 2001)، و XGBoost (Chen & Guestrin, 2016). وقُسمت البيانات 70/15/15 بين التدريب والتحقُّق والاختبار، مع معاينةٍ طبقية تحافظ على نسبة المتحوِّلين قرابة 7% في كل قسم. وطُبِّقت تقنية SMOTE على مجموعة التدريب وحدها حتى توازنت الفئتان (11,087 لكلٍ منهما) (Chawla et al., 2002)، ثم وُجِّدت مقاييس المتغيِّرات العددية. وقُيِّمت النماذج بمقاييس ملائمة لاختلال التوازن—الدقة والاستدعاء و F1 و ROC-AUC—مع ضبط عتبة القرار، وقُيِّرَ أفضلها بقيم SHAP المستندة إلى نظرية الألعاب التعاونية (Lundberg & Lee, 2017; Molnar, 2022).

التشغيل الإجرائي للمتغيِّرات وقياسها: لا يعتمد هذا البحث على استبيانٍ أو مقاييس تقريرٍ ذاتي، بل يقيس المتغيِّرات قياساً سلوكياً مباشراً من سجلات النشاط الفعلية للمنصة. فكلُّ متغيِّرٍ من المتغيِّرات النهائية البالغة 37 متغيِّراً محسوبٌ من أحداثٍ موقوتة (مثل عدد مرّات الدخول، ومدة الجلسة بالثواني، وعدد الميزات المستخدمة، والتفاعل مع الميزات المدفوعة)، ثم اشتُقت منها ميزاتٌ نسبية وزمنية ونوافذ متحركة. وتُحسب القيم المعروضة في الجدول 2 بوصفها المتوسطات الحسابية لكل مقياسٍ داخل كلٍّ من مجموعتي المتحوِّلين وغير المتحوِّلين، في حين تُقاس جودة التنبؤ بمقاييس ملائمة لاختلال التوازن هي الدقة والاستدعاء و F1 و ROC-AUC، وتُفسَّر مساهمة كل متغيِّرٍ بقيم SHAP.

المطلب الثاني: نتائج الفروق السلوكية ومحدِّدات التحوُّل:


يبدأ توصيفُ التوقع السلوكي من مقارنة متوسطات الانخراط بين المجموعتين. يُظهر الجدول 2 والشكل 1 أن المتحوِّلين أكثر نشاطاً في كل مقياس: يدخلون المنصة نحو ثلاثة أضعاف، ويقضون قرابة ثلاثة أضعاف الزمن، ويستخدمون ما يقارب ضعف عدد الميزات المتميزة. وهذه الفجوات الواضحة تؤكد أن الإشارات السلوكية المجموعة تمييزية فعلاً، وتمنح سبباً قوياً لتوقع قدرة النماذج على الفصل بين المجموعتين.

الجدول 2: متوسطات مقاييس الانخراط بحسب حالة التحوُّل

المقياس	المتحوِّلون (المتوسط)	غير المتحوِّلين (المتوسط)
عدد مرّات الدخول	28.7	10.2
مدة الجلسة (ثانية)	2,847	1,043
عدد الميزات المستخدمة	6.8	3.8

المصدر: من إعداد الباحثة اعتماداً على نتائج الدراسة، 2026.

الشكل 1: مقارنة متوسطات الانخراط بين المتحوّلين وغير المتحوّلين



المصدر: من إعداد الباحثة اعتماداً على نتائج الدراسة، 2026.

وعلى مستوى الارتباط الثنائي، جاء التفاعل مع الميزات المدفوعة (premium_actions) أقوى المتغيّرات ارتباطاً بالتحوُّل (0.342)، يليه عدد الأيام النشطة (0.318) ثم إجمالي مرّات الدخول (0.297). ويدعم ذلك قراءة «اكتشاف القيمة»: يميل المستخدم إلى الترقية بعد أن يختبر فعلاً الوظائف المدفوعة، فالانخراط المدفوع سابقةً أقرب للدفع من النشاط غير الموجّه. ولاستخلاص محدّدات التحوُّل، رُتبت أهمية الميزات عبر النماذج الثلاثة، ثم حُسبت قيم SHAP لأفضلها (XGBoost). يورد الجدول 3 القيم الخمس الأعلى، وجميعها موجبة الاتجاه؛ أي إن ارتفاع كلّ منها يدفع النموذج نحو التنبؤ بالتحوُّل، ويتصدّرها التفاعل مع الميزات المدفوعة (0.142)، يليه اتساق الانخراط (0.118) فنموّ الدخول (0.103). ويعني تصدُّر الاتساق والنموّ على حجم النشاط المجرد أن كيفية انخراط المستخدم — بانتظامٍ وتصاعدٍ — أهمُّ من مجرد شدّته.

الجدول 3: أعلى خمس قيم SHAP للنموذج الأفضل (XGBoost) واتجاه أثرها

الميزة	قيمة SHAP	اتجاه الأثر
التفاعل مع الميزات المدفوعة (premium_actions)	0.142	موجب
اتساق الانخراط (engagement_consistency)	0.118	موجب
نموّ تواتر الدخول (growth_login)	0.103	موجب
الأيام النشطة خلال 30 يوماً (days_active_30d)	0.098	موجب
نسبة النشاط المدفوع (premium_ratio)	0.091	موجب

المصدر: من إعداد الباحثة اعتماداً على نتائج الدراسة، 2026.

المبحث الثاني

المسار الزمني للتحوُّل ومن التنبؤ إلى التدخُّل

المطلب الأول: نتائج ديناميكيات الاستخدام عبر الزمن:


لا يتحدّد التحوُّل بحجم الانخراط في لحظةٍ بعينها فحسب، بل باتجاهه عبر الزمن. صُفِّف المستخدمون بحسب مسار انخراطهم، وفُورنت معدّلات تحوُّلهم كما في الجدول 4 والشكل 2. والنتيجة لافتة: يتحوُّل ذوو المسار المتزايد بمعدّل 19.4%—أي نحو ثلاثة أضعاف المتوسط العام، وأكثر من عشرة أضعاف معدّل ذوي المسار المتناقص (1.8%). ويثبت هذا التدرُّج أن التحوُّل مسألة زخمٍ لا مستوى، ويبرّر إدراج ميزات النمو والاتجاه مثل growth_login ضمن النماذج التنبؤية.

الجدول 4: معدّل التحوُّل بحسب مسار الانخراط عبر الزمن

مسار الانخراط	نسبة المستخدمين	معدّل التحوُّل
متناقص	52%	1.8%
مستقر	31%	6.7%
متزايد	17%	19.4%

المصدر: من إعداد الباحثة اعتماداً على نتائج الدراسة، 2026.

الشكل 2: معدّل التحوُّل بحسب مسار الانخراط



المصدر: من إعداد الباحثة اعتماداً على نتائج الدراسة، 2026.

ويعرّز هذا البُعد الزمني كونُ السلوك المبكر حاسماً؛ إذ يتشكّل التحوُّل غالباً في المراحل الأولى من دورة حياة المستخدم، وتقع معظم حالاته خلال الأسابيع الاثني عشر الأولى. وحين تُدمج هذه المُحدِّدات السلوكية والزمنية في نموذج تنبؤي، تُترجم إلى قدرة تنبؤية ملموسة: حقّق XGBoost أفضل أداءٍ على مجموعة الاختبار (2,553 مستخدماً) في كل المقاييس، متفوّقاً بفارقٍ

دالٍ إحصائياً (اختبار مكنمار: مقابل الغابة العشوائية $p = 0.027$ ، ومقابل الانحدار اللوجستي $p < 0.001$)، كما يوضِّح الجدول 5.

الجدول 5: الأداء المقارن للنماذج الثلاثة على مجموعة الاختبار

النموذج	الدقة الكلية	الدقة	الاستدعاء	F1	AUC
الانحدار اللوجستي	0.835	0.421	0.382	0.400	0.722
الغابة العشوائية	0.861	0.498	0.461	0.479	0.778
XGBoost	0.878	0.547	0.507	0.526	0.804

المصدر: من إعداد الباحثة اعتماداً على نتائج الدراسة، 2026.

ومع أن هذه النتائج مشجعة، فإنها تؤكد أيضاً أن التنبؤ بالتحوُّل مسألة صعبة بطبيعتها؛ إذ يلتقط السلوك جزءاً من التباين فحسب، بينما تتأثر القرارات بعوامل نفسية (القيمة المدركة والاستعداد للدفع) وخارجية (الميزانية والمنافسة) لا تظهر بالكامل في البيانات السلوكية. وتتسق هذه المستويات من الأداء مع دراسات التنبؤ بسلوك العملاء السابقة (Coussement & Van den Poel, 2008؛ Verbeke et al., 2012).

المطلب الثاني: من التنبؤ إلى التدخل الموجّه:

تكتمل قيمة النموذج حين يتحوَّل من أداة تنبؤ إلى أداة قرار. وأولى روافع ذلك عتبة القرار؛ فكما يبيِّن الجدول 6، يرفع خفض العتبة إلى 0.45 الاستدعاء إلى 0.548 ويحقِّق أعلى قيمة لـ F1 (0.530) على حساب يسير من الدقة، بينما يرفع رفعها إلى 0.60 الدقة إلى 0.632 مقابل تفويت مزيد من المتحوِّلين. فالعتبة إذن معيار قابل للضبط بحسب أولويات المنشأة: يُخفِّض حين يكون تفويت متحوِّل مكلفاً، ويُرفع حين يكون الإنفاق على تواصل غير مثمر هو الشاغل الأكبر.

الجدول 6: تحليل عتبة القرار لنموذج XGBoost

العتبة	الدقة	الاستدعاء	F1
0.45	0.513	0.548	0.530
0.50	0.547	0.507	0.526
0.60	0.632	0.421	0.505

المصدر: من إعداد الباحثة اعتماداً على نتائج الدراسة، 2026.

والرافعة الثانية هي قابلية التفسير التي توقِّرها قيم SHAP؛ فهي لا تكتفي بترتيب المُحدِّدات، بل تكشف اتجاه أثر كلٍّ منها وحجمه، وتتيح تفسيراً على مستوى المستخدم الفرد، فتحوِّل النموذج من «صندوق أسود» إلى أداة دعم قرار تُمكن من تدخّلاتٍ مخصَّصة بدل الحملات المعممة. ويلخِّص الجدول 7 توصياتٍ عملية موزَّعة على الأدوار التنظيمية الأكثر صلةً بعملية التحوُّل.

الجدول 7: توصيات عملية بحسب الدور التنظيمي

الدور	التوصيات
مدير المنتج	بناء رحلاتٍ لاكتشاف الميزات، وتتبع اتساق الانخراط، وتحديد محطات التفعيل المبكر.
فرق التسويق	التقسيم بحسب احتمال التحوُّل، واختبار الحوافز المختلفة، وضبط توقيت الرسائل.
فرق علم البيانات	إعادة تدريب النماذج دورياً، ومراقبة أهمية الميزات، ودمج SHAP في لوحات المتابعة.
القيادة التنفيذية	الاستثمار في البنية التحتية للبيانات، وموازنة الميزات المجانية والمدفوعة، وترسيخ ثقافة قائمة على البيانات.

المصدر: من إعداد الباحثة اعتماداً على نتائج الدراسة، 2026.

خاتمة:

أعاد هذا البحث تأطير التحوُّل من الاستخدام المجاني إلى المدفوع في منتجات SaaS بوصفه مساراً سلوكياً متراكماً قوامه اكتشاف القيمة وتنامي الانخراط، لا قراراً لحظياً. وتحليل بيانات سلوكية فعلية لـ 17,024 مستخدماً على مدى عام، تبين أن للمتحوِّلين توقيعاً سلوكياً مميزاً—دخولٌ أكثر، وجلساتٌ أطول، واستخدامٌ أوسع للميزات—وأن التفاعل مع الميزات المدفوعة واتساق الانخراط ونموه هي أقوى محددات التحوُّل. كما ثبت أن اتجاه الانخراط عبر الزمن مؤشِّرٌ حاسم، إذ بلغ معدَّل التحوُّل لدى ذوي المسار المتزايد 19.4% مقابل 1.8% لذوي المسار المتناقص. وحقق نموذج XGBoost أفضل أداء (F1 = 0.526، و ROC-AUC = 0.804) بفارقٍ دالٍّ إحصائياً، وأتاحت قيم SHAP تفسيراً شفافاً يحوِّل التنبؤ إلى تدخُّلٍ موجّه.

وتوصي الدراسة المنشآت بالانتقال من التخمين إلى الاستهداف المبني على الأدلة عبر: رصد المسار الزمني للانخراط مبكراً، وتوجيه المستخدمين نحو تجربة الميزات المدفوعة، ومكافأة الانتظام والنمو، وضبط عتبة القرار وفق الأولويات، ودمج التفسير في لوحات المتابعة. وتبقى النتائج مقيّدةً باعتمادها على منتج واحد وبياناتٍ سلوكية تاريخية دون العوامل النفسية والخارجية، وهو ما يفتح آفاقاً بحثية مستقبلية تشمل التحقق عبر منتجاتٍ متعدّدة، ودمج البيانات النفسية والخارجية، وبناء أنظمة تنبؤ آنية، واستكشاف النماذج التسلسلية والاستدلال السببي.

التوصيات:

وبناءً على ما تقدّم، تتجّه التوصيات العملية إلى توجيه المستخدمين نحو الميزات المدفوعة عبر جولاتٍ تعريفية وتجارب «جرب المدفوع»، وتحفيز الانخراط المتسق والمتنامي عبر التلعيب وتتبع التقدّم، والتركيز على محطات التفعيل المبكر، وتوجيه التواصل المخصّص نحو المستخدمين الذين يرصدهم النموذج بوصفهم الأعلى احتمالاً للتحوُّل.

بيانات الإفصاح:

- الموافقة الأخلاقية والموافقة على المشاركة: تم الاتفاق على المشاركة في البحث وفقاً للإرشادات الخاصة بالمجلة.
- توافر البيانات والمواد: كافة البيانات والمواد متاحة عند الطلب.
- مساهمة المؤلفين: يتحمل المؤلفين مسؤولية كافة محتويات البحث والتحليل والمنهجية والمراجعة الكاملة.
- تضارب المصالح: لا يوجد تضارب في المصالح لأي طرف من خلال تصميم البحث وتقديمه وتقييمه.
- التمويل: لا يوجد أي تمويل مخصص لهذا البحث.
- شكر وتقدير: الشكر الجزيل لمجلة التطوير العلمي "للدراستات والبحوث" (JSD) على الدعم والإرشادات ([/https://jsd.sdasmart.org/jsd](https://jsd.sdasmart.org/jsd))

قائمة المراجع:

- صالح، محمد نجيب، وبشير، كمال، ومصديق، محمد. (2026). تصميم نموذج تنبؤي لتشخيص مرض السكري باستخدام تقنيات التعلم الآلي والتنقيب في البيانات. مجلة التطوير العلمي للدراسات والبحوث (JSD)، 7(25).
- Salih, M. N., Bashir, K., & Mosadag, M. (2026). Designing a predictive model for diabetes diagnosis using machine learning and data mining techniques. Journal of Scientific Development for Studies and Research (JSD), 7(25).
- Breiman, L. (2001). Random forests. Machine Learning, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. Journal of Artificial Intelligence Research, 16, 321–357. <https://doi.org/10.1613/jair.953>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785–794). Association for Computing Machinery. <https://doi.org/10.1145/2939672.2939785>
- Coussement, K., & Van den Poel, D. (2008). Churn prediction in subscription services: An application of support vector machines while comparing two parameter-selection techniques. Expert Systems with Applications, 34(1), 313–327. <https://doi.org/10.1016/j.eswa.2006.09.038>
- Hamari, J., Hanner, N., & Koivisto, J. (2017). Service quality explains why people use freemium services but not if they go premium: An empirical study in free-to-play games. International Journal of Information Management, 37(1), 1449–1459. <https://doi.org/10.1016/j.ijinfomgt.2016.09.004>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. In Advances in Neural Information Processing Systems 30 (pp. 4765–4777). Curran Associates.



- Molnar, C. (2022). Interpretable machine learning: A guide for making black box models explainable (2nd ed.). Independently published.
- Verbeke, W., Dejaeger, K., Martens, D., Hur, J., & Baesens, B. (2012). New insights into churn prediction in the telecommunication sector: A profit driven data mining approach. *European Journal of Operational Research*, 218(1), 211–229. <https://doi.org/10.1016/j.ejor.2011.09.031>
- Oredo, J. O. (2025). Modelling users' intention to migrate from free to premium personal cloud storage in freemium business models: A machine learning approach. *African Journal of Science, Technology, Innovation and Development*, 17(6), 845–868. <https://doi.org/10.1080/20421338.2025.2545112>
- Shang, Y., Jiang, J., Zhang, Y., Zhang, R., & Liu, P. (2024). When does a freemium business model lead to high performance? A qualitative comparative analysis based on fuzzy sets. *Heliyon*, 10(3), e25149. <https://doi.org/10.1016/j.heliyon.2024.e25149>
- Sithipolvanichgul, J., Chen, C., Land, J., & Ractham, P. (2024). Motivations in the adoption and conversion of freemium services: Insights for digital entrepreneurship. *Review of Managerial Science*.
- Suguna, R., Suriya Prakash, J., Aditya Pai, H., Mahesh, T. R., Vinoth Kumar, V., & Yimer, T. E. (2025). Mitigating class imbalance in churn prediction with ensemble methods and SMOTE. *Scientific Reports*, 15, 16256. <https://doi.org/10.1038/s41598-025-01031-0>
- Zhang, L., & Duan, J. (2025). Longer or shorter? A large-scale randomized field experiment on the impact of free trial duration on sustainable user conversion in the Freemium model. *Frontiers in Psychology*, 16, 1568868. <https://doi.org/10.3389/fpsyg.2025.1568868>