



ALBA

ISFIC RESEARCH AND SCIENCE JOURNAL



Baseada na plataforma OJS. Licença Creative Commons BY 4.0
ISSN PRINT: 3006-2489; ISSN ONLINE: 3006-2470
1ª ed, Vol. 1, No. 12, setembro, 2026, Plataforma OJS
<https://alba.ac.mz/index.php/alba/issue/view/16>
albaisfic@gmail.com; alba@isfic.ac.mz

02 - 09 | 2026

GESTÃO ESTRATÉGICA DO CAPITAL HUMANO NA ERA DA IA: MODELOS PARA A MITIGAÇÃO DO ABANDONO ESCOLAR

Strategic Human Capital Management in the Age of AI: Models for Reducing School Dropout Rates

Gestión estratégica del capital humano en la era de la IA: modelos para reducir el abandono escolar

Nkanga Pedro¹, Paulo Fazendeiro², Maria Vita³, Mampuya Kinda Fidele⁴, Pedro Vita⁵

¹Nkanga Pedro, Mestre, Instituto Politécnico da Universidade Kimpa Vita, Angola, 0000-0002-9322-5692, nkangapedroinfo@gmail.com.

²Paulo Fazendeiro, Ph.D., Universidade da Beira Interior, Portugal, 0000-0001-6054-7188, pande@ubi.pt.

³Maria Vita, Licenciada, Escola Superior de Tecnologia e Gestão da Universidade do Porto, Portugal, mvida523@gmail.com.

⁴Mampuya Kinda Fidel, Ph.D., Instituto Politécnico da Universidade Kimpa Vita, Angola, 0000-0002-3114-5179, fmkinda@yahoo.fr.

⁵Pedro Vita, Ph.D., Reitoria da Universidade Kimpa Vita, Angola, pedrovitapv@hotmail.com.

Autor para correspondência: nkangapedroinfo@gmail.com

Data de recepção: 09-05-2026

Data de aceitação: 15-06-2026

Data da Publicação: 02-09-2026

Como citar este artigo: Pedro, N., Fazendeiro, P., Vita, M., Fidele, M. K., & Vita, P. (2026). *Gestão estratégica do capital humano na era da IA: modelos para a mitigação do abandono escolar*. VIII Simpósio de Economia e Gestão da Lusofonia – Universidade de Santiago – Cabo Verde. ALBA – ISFIC Research and Science Journal, 1(12), pp. 279-291. <https://alba.ac.mz/index.php/alba/issue/view/16>

RESUMO

O abandono escolar no ensino superior angolano é, ao mesmo tempo, uma perda de capital humano e um problema financeiro real para as instituições. Neste artigo, analisamos a aplicação de técnicas de Aprendizagem Automática (AA), nomeadamente K-Prototypes para aglomeração de perfis e Random Forest, SVM e Decision Tree para identificar precocemente alunos em risco de

abandonar a Universidade Kimpa Vita (UNIKIVI). Utilizamos dados reais de 4.354 alunos, distribuídos em cinco cursos, ao longo de um percurso de sete anos letivos (2016/2017-2022/2023). Os modelos atingiram taxas de precisão entre 93% e 95%, o que, na prática, os torna ferramentas úteis para decidir onde alocar bolsas e apoios psicopedagógicos. Quanto aos dados de abandono, os números falam por si:

16,6% dos alunos saíram sem concluir o curso, e a maior concentração ocorreu nos cursos de Contabilidade e Gestão, Engenharia Informática e Agronomia. Chegamos à conclusão de que adotar este tipo de governança baseada em dados não é apenas tecnicamente viável; é economicamente sensato para todas as instituições lusófonas que queiram ser financeiramente mais robustas e contribuir para a formação da mão de obra qualificada de que Angola e os países de língua portuguesa precisam.

Palavras-chave: Resiliência económica, Gestão do capital humano, Inteligência artificial, Abandono escolar, Ensino superior angolano.

ABSTRACT

Dropout rates in Angolan higher education represent both a loss of human capital and a real financial problem for institutions. In this article, we analyze the application of machine learning (ML) techniques, specifically K-Prototypes for profile clustering, and Random Forest, SVM, and Decision Tree for early identification of students at risk of dropping out at Kimpa Vita University (UNIKIVI). We used real-world data from 4,354 students across five programs over a seven-year academic period (2016/2017–2022/2023). The models achieved accuracy rates between 93% and 95%, making them useful tools for deciding where to allocate scholarships and psychopedagogical support. As for dropout data, the numbers speak for themselves: 16.6% of students left without completing their degree, with the highest concentration in the Accounting and Management, Computer Engineering, and Agronomy programs. We concluded that adopting this type of data-driven governance is not only technically feasible but also economically sensible for all Portuguese-speaking institutions that want to become more financially robust and help train the skilled workforce Angola and Portuguese-speaking countries need.

Keywords: Economic resilience, Human capital management, Artificial intelligence, School dropout rates, Angolan higher education.

RESUMEN

El abandono escolar en la enseñanza superior angoleña supone, a la vez, una pérdida de capital humano y un problema financiero real para las instituciones. En este artículo analizamos la aplicación de técnicas de aprendizaje automático (AA), concretamente K-Prototypes para la agrupación de perfiles y Random Forest, SVM y Decision Tree para identificar de forma precoz a los estudiantes en riesgo de abandonar la Universidad Kimpa Vita (UNIKIVI); utilizamos datos reales de 4.354 estudiantes, repartidos en cinco titulaciones, a lo largo de siete cursos académicos (2016/2017-2022/2023). Los modelos alcanzaron tasas de precisión entre el 93 % y el 95 %, un resultado que, en la práctica, los convierte en herramientas útiles para decidir dónde asignar becas y ayudas psicopedagógicas. En cuanto a los datos de abandono, las cifras hablan por sí solas: el 16,6 % de los estudiantes abandonó sin terminar la carrera, y la mayor concentración se observó en las carreras de Contabilidad y Gestión, Ingeniería Informática y Agronomía. Llegamos a la conclusión de que adoptar este tipo de gobernanza basada en datos no solo es técnicamente viable, sino que también resulta económicamente sensato para todas las instituciones de habla portuguesa que deseen ser financieramente más sólidas y contribuir a la formación de la mano de obra cualificada que necesitan Angola y los países de habla portuguesa.

Palabras clave: Resiliencia económica, gestión del capital humano, inteligencia artificial, abandono escolar, enseñanza superior en Angola.

Contribuição de autoria (por autor):

Autor 1: Concepção da ideia, pesquisa e revisão de literatura, compilação da informação resultante dos instrumentos., redação do original (primeira versão). Treinamento do modelo e compilação dos resultados.

Autor 2: Revisão da aplicação do padrão bibliográfico e proposta de um modelo treinado. Aconselhamento geral sobre o tema abordado.

Pedro, N., Fazendeiro, P., Vita, M., Fidele, M. K., & Vita, P. (2026). *Gestão estratégica do capital humano na era da IA: modelos para a mitigação do abandono escolar*

ideia de que estudar é um investimento que torna as pessoas mais capazes e, no conjunto, faz a economia crescer. O problema é visível quando esse investimento não é concluído. Quando um estudante abandona o curso antes de concluí-lo, a conta não fica só com ele, mas é distribuída entre todos os envolvidos. O estudante perde a qualificação que desejava e almejava. A família disponibiliza meios financeiros sem ver o diploma chegar, como parte de um plano e de uma meta traçada. A instituição utiliza recursos humanos, como professores, e outros recursos administrativos, sem obter resultados. E o Estado também sai a perder com parte do financiamento desse percurso, directa ou indirectamente. Em contextos com recursos escassos, como é o caso das universidades angolanas, este desperdício é ainda mais grave e se reflete numa perda significativa. Mincer (1974) mostrou que a taxa de retorno da educação é significativamente superior à de outros investimentos nas economias em desenvolvimento, o que significa que cada ano de formação incompleta representa uma perda relativa amplificada. O abandono escolar não é, portanto, apenas um problema social; tem expressão económica directa. No contexto angolano, a literatura disponível aponta como factores determinantes do abandono as dificuldades financeiras das famílias, a fraca preparação dos estudantes no ensino secundário, a diferença entre o que os estudantes perspectivavam do curso e encontraram na prática, e as pressões do mercado de trabalho informal, que frequentemente recruta jovens antes que terminem a formação (Capitão, 2021; Francisco, 2021). Estes factores não são apenas sociais, mas também têm expressão económica directa e podem ser parcialmente capturados em dados académicos.

Sustentabilidade financeira das Instituições de Ensino Superior

A sustentabilidade financeira de uma universidade depende, em grande parte, da sua capacidade de manter em frequência os estudantes que se matricularam ao longo do percurso. As propinas são uma fonte de receita recorrente que desaparece quando o estudante abandona os estudos. Mas o problema vai além da receita perdida: os custos fixos docentes, administrativos e de instalações mantêm-se independentemente de quantos estudantes concluíram a formação. O resultado é uma estrutura de custos rígida e uma base de receita instável, o que, por definição, configura uma equação de fragilidade institucional e desequilíbrio organizacional. Há vários anos, nos modelos de governança financeira do Ensino Superior, as métricas de retenção são consideradas indicadores-chave de desempenho (KPI). Tinto (1987) demonstrou empiricamente que a taxa de retenção é o melhor preditor da saúde financeira de longo prazo de uma universidade. Adoptar sistemas de alerta precoce baseados em dados académicos enquadra-se não somente, como inovação tecnológica, mas também, como uma decisão de gestão financeira responsável e sustentável.

Modelos de governança apoiados em dados no Ensino Superior


A literatura internacional sobre Educational Data Mining (EDM) e Learning Analytics tem consolidado, nas últimas décadas, um conjunto de abordagens que transformam dados académicos em suporte à decisão institucional (Baker & Inventado, 2014). Os modelos de clustering permitem segmentar populações estudantis em perfis de risco

Clas_atual	Classe que está a frequentar ou frequentou atualmente
Semestre	Semestre que pode ser 1 ou 2 semestre
Período	Período que aluno frequentou
Esta_civil	Estado civil do aluno
Naturalidade	Naturalidade do aluno
Habil_pai	Habilitação do pai
Habil_mãe	Habilitação da mãe
Insti_Proven	Instituição de Proveniência do aluno
Corresp_inst_curso	Código da correspondência do curso de proveniências (valor 1 representa a correspondência do curso frequentado na instituição anterior e 0 caso contrário)
Curso	Curso do aluno (Informática, Enfermagem, Contabilidade e Gestão, Agronomia e Hidráulica e saneamento de água)
Ano_Acad	Ano académico (dados recolhidos de 2016/2017 a 2022/2023)
Status	Situação do aluno, que pode ser "Cursando", "Concluído" ou "Abandonado"; neste caso, verificaram-se os últimos registos (ano académico 2022) dos dados recolhidos.

Fonte: De Autores

No conjunto final, após a distribuição, obteve-se o seguinte resultado: 43,6% dos alunos concluíram o curso (1 899 alunos), 39,8% ainda estavam a frequentar (1 732 alunos), e 16,6% foram motivados a abandonar (723 alunos). Este desequilíbrio entre grupos espelha um problema metodológico, se treinarmos o modelo com estes números tal como estão, o mesmo tende a ignorar a classe mais pequena, precisamente a que mais nos interessa. Para resolver o problema recorreu-se à técnica SMOTE (Synthetic Minority Oversampling Technique), que gera amostras sintéticas da classe minoritária para equilibrar o conjunto de treino. As etapas do estudo estão ilustradas na Figura 1.

Figura 1: Esquema do treino



Fonte: De Autores

Variáveis e KPIs académicos

As variáveis selecionadas para o modelo foram definidas pelo seu valor preditivo, e não pela facilidade de recolha. Entre os atributos com maior relevância para a previsão do abandono, destacam-se: o número de reprovações acumuladas (Num_repro), o número de matrículas realizadas (N_inscri), o número de abandonos anteriores (N_abando), o ano de ingresso e a última matrícula registada (Ano_ingres / Ulti_matri) e, a correspondência entre o curso frequentado e a formação anterior do aluno (Corresp_inst_curso). Na prática, estas

No **Resultados e discussão**, a análise de cluster gerada foi incorporada como atributo adicional no conjunto de treino dos modelos de classificação supervisionada. Para fins de comparação, foram testados três algoritmos: Support Vector Machine (SVM), Árvore de Decisão (DT) e Floresta Aleatória (Random Forest - RF). A avaliação foi conduzida com validação cruzada k-fold (k=5), em dados balanceados e não balanceados. As métricas reportadas incluem precisão (accuracy), precisão por classe (precision), sensibilidade (recall) e F1-score.

Cinco perfis dos alunos em risco: o que os dados revelam

A segmentação K-Prototypes identificou cinco perfis de alunos com características e níveis de risco bem diferenciados. Não representam categorias abstratas; são grupos reais de alunos com padrões de comportamento académico distintos e variáveis, que exigem intervenções igualmente distintas do ponto de vista institucional.

Tabela 3: Perfis de risco identificados pelo modelo K-Prototypes na UNIKIVI

Cluster	Perfil dominante	Cursos principais	Taxa de abandono	Risco
0	Jovem (<29 anos), 2.º-3.º ano, nunca reprovou (83%)	Hidráulica	5%	Baixo
1	Adulto (<39 anos), 3.º ano, reprovações frequentes (78%)	Contab., Inform., Agron.	40%	Muito alto
2	Adulto (<39 anos), 2.º-3.º ano, reprovações moderadas (66%)	Informática, Contab.	31%	Alto
3	Jovem (<29 anos), 3.º ano, nunca reprovou (87%)	Enfermagem	0%	Muito baixo
4	Adulto (<39 anos), 4.º-5.º ano, poucas reprovações (70%)	Enfermagem	16%	Médio

Fonte: De Autores

O que se destaca imediatamente desta segmentação é a heterogeneidade dos riscos. Os Clusters 1 e 2 concentram os alunos de maior risco e instabilidade, maioritariamente nos cursos de Contabilidade e Gestão, Engenharia Informática e Agronomia. Nos Clusters 0 e 3, os alunos de Hidráulica e de Enfermagem apresentam trajetórias mais estáveis, com taxas de abandono inferiores a 5%. Esta diferença não é aleatória; reflete de forma significativa as características estruturais de cada curso. A enfermagem tem uma procura de mercado imediata, clara e precisa, o que mantém a motivação dos

alunos mais elevada ao longo do percurso. Do ponto de vista da gestão, esta informação tem implicações directas na alocação dos recursos evidenciados. De certo modo, faz pouco sentido distribuir bolsas uniformemente entre todos os alunos, quando os dados mostram que os do Cluster 3 têm probabilidade de abandono inferior a 1%. Concentrar o apoio financeiro e psicopedagógico nos Clusters 1 e 2 é, simultaneamente, mais eficiente e mais justo.


Baseada na plataforma OJS. **Licença Creative Commons BY 4.0**
ISSN PRINT: 3006-2489; ISSN ONLINE: 3006-2470
1ª ed, Vol. 1, No. 12, setembro, 2026, Plataforma OJS
<https://alba.ac.mz/index.php/alba/issue/view/16>
albasific@gmail.com; alba@isfic.ac.mz

Precisão dos modelos preditivos e valor para a gestão

Os três modelos de classificação testados até ao momento, apresentaram desempenhos consistentemente elevados. Com dados balanceados por SMOTE, a SVM atingiu 94% de precisão, a Árvore de Decisão 95% e

o Random Forest 95,6%. A Figura (3) mostra a distribuição dos alunos pelos diferentes clusters, com testes realizados com a variável Status (lado esquerdo) e sem ela (lado direito).

Figura 3: Distribuição de aluno em cluster



Fonte: De Autores

Com dados não balanceados, os resultados foram ligeiramente superiores para o RF (96%), embora com maior risco de sobreajuste à classe majoritária.

balanceados e não balanceados. A sua arquitetura de ensemble, que combina múltiplas árvores de decisão treinadas em subconjuntos aleatórios dos dados, torna-o mais resistente ao sobreajuste, uma componente que pesa bastante quando se trabalha com um conjunto de dados relativamente pequeno, como é o caso (4 354 registos). Uma precisão de 95% traduz-se, na prática, em algo simples: de cada 100 alunos que o modelo sinaliza como em risco de abandono, cerca de 5% estão incorretamente sinalizados. É uma margem aceitável. Intervir preventivamente junto de um aluno que, no fundo, não precisava necessariamente de apoio custa muito menos do que não intervir junto de um que precisava e acabou por sair por falta de recursos não evidenciados a tempo e a hora.

Tabela 4: Comparação de desempenho dos modelos de classificação (validação cruzada k-fold, k=5)

Modelo	Dados não balanceados	Dados balanceados	Recomendação
SVM	93,9%	94,0%	Adequado
Árvore de Decisão	95,0%	95,0%	Adequado
Random Forest	96,0%	95,6%	Preferido

Fonte: De Autores

O Random Forest revelou-se o modelo mais robusto e prático, com a melhor matriz de confusão e a maior consistência entre dados

Análise Financeira: O custo real do abandono no contexto da UNIKIVI

Para perceber, de forma credível, o peso económico do abandono na UNIKIVI, é preciso ir além da propina oficial. O que uma família paga por mês para manter um filho a estudar é bem mais do que o montante previsto no decreto. No turno diurno, a propina está fixada em 1 900 kwanzas mensais, ao abrigo do Decreto Presidencial n.º 124/20 (Embaixada da República de Angola em Portugal, 2021). Até aqui, parece razoável. Mas a UNIKIVI está situada na periferia da cidade do Uíge, e caminhar todos os dias é dispendioso. A deslocação de ida e volta representa cerca de 400,00 kwanzas por dia, o que, assumindo 20 dias úteis por mês, totaliza 8 000,00 kwanzas. A propina deixou de ser o principal problema em questão. O custo mensal total para um estudante do turno diurno fica em torno de 9 900,00 kwanzas. No turno pós-laboral, a situação é estruturalmente mais pesada e complicada, de modo que a propina passa a 15 000,00 kwanzas mensais, ao abrigo do Decreto Presidencial n.º 124/20, que estabelece que os alunos do período noturno participam em 60% do custo anual por aluno, face aos 10% do período diurno. Somando o transporte noturno, que tende a ser mais caro, e menos acessível por razões de segurança, disponibilidade e outros factores refletindo a realidade vivida, o custo mensal ultrapassa os 23 000,00 kwanzas.

Tabela 5: Estrutura de custos mensais de um aluno da UNIKIVI vs. salário mínimo nacional (2024)

Componente de Custo	Turno Diurno (Kz/mês)	Turno Nocturno (Kz/mês)
Propina (UNIKIVI pública)	1 900,00	15 000,00
Transporte (est. 20 dias úteis)	8 000,00	+ 8 000,00
Total Mensal Estimado	≈ 9 900,00	≈ 23 000,00
Salário mínimo nacional (set. 2024)	70 000,00	70 000,00
Custo como % do salário mínimo	≈ 14%	≈ 33%

Fonte: Decreto Presidencial n.º 124/20

O salário mínimo nacional foi fixado em 70 000,00 kwanzas por mês pelo Decreto Presidencial n.º 152/24, de 17 de julho de 2024 (Angola, 2024). Para uma família com esse rendimento, no contexto do Uíge, muitas ficam abaixo desse valor; manter um filho a estudar no turno diurno representa cerca de 14% do rendimento mensal. No período noturno, essa percentagem sobe para 33%. Quando há mais de um filho na idade universitária, a matemática torna-se inviável e quase impossível em tempo integral. Este quadro financeiro ajuda a explicar, com dados concretos, por que o Cluster 1, onde se concentram estudantes mais velhos dos cursos de Contabilidade, Informática e Agronomia, apresenta uma taxa de abandono de 40%. Estes estudantes são maioritariamente trabalhadores que estudam à noite, carregando simultaneamente responsabilidades profissionais, forte pressão social e o encargo da propina noturna. Quando surge uma dificuldade económica, como a perda de um emprego, uma despesa inesperada ou a simples impossibilidade de pagar o transporte durante semanas, a decisão de abandonar o curso não vem da falta de motivação académica, da morte do sonho de

Pedro, N., Fazendeiro, P., Vita, M., Fidele, M. K., & Vita, P. (2026). *Gestão estratégica do capital humano na era da IA: modelos para a mitigação do abandono escolar* permite direccionar esses recursos para onde são mais necessários e relevantes não é apenas tecnicamente interessante: é financeiramente responsável, viável e enriquecedor.

O abandono escolar no ensino superior angolano é, antes de mais, um problema económico. Cada estudante que sai sem diploma representa um investimento incompleto da família na tentativa de formar um quadro da instituição e do Estado. A verdadeira questão não é se as universidades angolanas podem dar-se ao luxo de implementar sistemas preditivos de gestão e prevenção do risco académico, ou se podem continuar a dar-se ao luxo de não o fazer. Este estudo demonstrou que, com os dados que os sistemas de gestão académica já produzem, é possível construir modelos preditivos com precisão e assertividade superiores a 93% para identificar precocemente estudantes em risco. A UNIKIVI é um caso demonstrador: com 4 354 registos, cinco cursos e sete anos de histórico académico, foi possível segmentar a população estudantil em cinco perfis de risco distintos, e treinar classificadores com desempenho consistentemente elevado e credível. As implicações estratégicas são directas. Para as instituições de ensino superior lusófonas que pretendam reforçar a sua resiliência financeira e contribuir para os objectivos nacionais de desenvolvimento e formação de quadros, a adopção de modelos de governança baseados em dados não é uma ambição para o futuro, mas uma necessidade de gestão no presente, constituindo um componente das respostas actuais. Os dados já existem, e os algoritmos estão disponíveis e prontos para serem implementados. O que falta, na maior parte dos casos, é a decisão

institucional de transformar esses dados em informação estratégica e em uma ferramenta de dinamismo. Num contexto mais amplo, a lusofonia debate hoje como construir economias mais resilientes e saudáveis, com potencial, em plena era da inteligência artificial. A educação superior é a principal alavanca para a formação de capital humano qualificado nesses países. Se o sistema educativo perder sistematicamente e de forma abrupta estudantes antes da conclusão, essa alavanca deixa de funcionar independentemente de quantas instituições sejam abertas, com cursos de maior procura e políticas acessíveis ou, de quantas vagas sejam criadas. A gestão preditiva do abandono escolar é, por isso, uma contribuição directa para a resiliência e ascensão económica dos países lusófonos: começa num campus em Uíge e termina na estrutura produtiva de um país. Como trabalho futuro, propõe-se a expansão do modelo a outras instituições do sistema de Ensino Superior angolano para validar a sua generalização, bem como o desenvolvimento de uma interface que permita a gestores académicos sem formação técnica em ciência de dados aceder às previsões do modelo de forma autónoma e regular, constituindo, assim, um avanço na resolução de uma fissura identificada.

REFERÊNCIA BIBLIOGRÁFICA

- Angola. (2020). Decreto Presidencial n.º 124/20: Regulamento sobre propinas, taxas e emolumentos das instituições públicas de ensino superior. Diário da República.
- Angola. (2022). Plano Nacional de Desenvolvimento 2023–2027. Ministério do Plano e Desenvolvimento Territorial.
- Angola. (2024, 17 de julho). Decreto Presidencial n.º 152/24: Fixa o montante do salário mínimo nacional em Kz

