

بين مجموعتين (مثل الطلاب الإناث مقابل (True Positive Rate) ”الفرق في“ معدل الإيجابيات الحقيقية EOD يقيس مؤشر فذلك يعني حصول كلا المجموعتين على نفس نسبة النجاح الفعلية (توزيع متساوٍ للفرص). وإذا كان $EOD = 0$ إذا كان الذكور) بلغت 95% للطلاب (TPR) إذا حقق نظام الذكاء الاصطناعي نسبة نجاح حقيقية فالميزة تكون للمجموعة المفضلة $EOD > 0$ ضئيلاً (ضمن نطاق $\pm 3\%$) مؤشراً على عدالة مقبولة نسبياً. إذا $EOD < 0$ الذكور و92% للطالبات، في الممارسة العملية، يُعتبر فرق من أساليب معالجة الانحياز قبل تدريب (Re-weighting) تجاوز الفارق هذا النطاق، أدوات ضبط الانحياز: إعادة وزن العينات النموذج، تقنية إعادة وزن العينات. تعتمد الفكرة على تعديل أوزان عينات التدريب بحيث لا تكون فئات حساسة (مثل الجنس أو العرق) ممثلة بشكل مغاير غير عادل. إذ يتم تحليل توزيع الصفة الحساسة في البيانات وتحديد معامل وزن لكل عينة. إذا كان بعد إعادة الوزن يتعلم org. حجم عينات إحدى الفئات أقل، تمنح عيناتها أوزاناً أكبر بحيث تُقابل عينات الفئة الأكبر وزناً أقل النموذج من بيانات أكثر توازناً، مما يعزز إنصاف التوقعات (مثلاً يُقلل الفارق في معدلات النجاح الحقيقية بين المجموعات سالبة) لكن الفرق ظل EOD) أي أن النظام أعطى ميزة طفيفة للفئة الذكورية org، من الصفر). كمثال توضيحي EOD ويُقرب ضمن $\pm 3\%$ (نطاق التسامح المعتاد)، مما يشير إلى تحيز ضئيل نسبياً. بعد تطبيق إعادة وزن العينات على بيانات التدريب، بذلك يتحقق التكافؤ الكامل تقريباً في فرص التقييم بين المجموعتين. $EOD \approx 0\%$ فيصبح