



مجلة البحوث المالية والتجارية

المجلد (22) – العدد الثاني – إبريل 2021



محاكاة توزيعات واييل المختلطة المحدودة لنمذجة حجم المطالبة التأمينية

Simulation of finite mixture Weibull distributions for modeling insurance claim

الباحث/ احمد رمضان محمد المتولى

المدرس المساعد بقسم الاحصاء والرياضيات والتأمين

بكلية التجارة- جامعة بورسعيد

اشراف

أ.م.د/ رانيا احمد حامد

استاذ الاحصاء التطبيقى المساعد

كلية التجارة-جامعة بورسعيد

أ.د/ محمد المهدي محمد على

استاذ الرياضيات والاحصاء الاكثوارى المتفرغ

كلية التجارة-جامعة بورسعيد

رابط المجلة: <https://jsst.journals.ekb.eg/>

الملخص:

تعتبر التوزيعات المستمرة من التوزيعات الهامة المستخدمة فى التقدير والتنبؤ بحجم الخسائر المالية المتوقعة. من هنا ، تسعى هذه الورقة البحثية الى عرض طريقتى تقدير لمجموعة من التوزيعات المختلطة المحدودة والمتطابقة والتي يمكن استخدامها فى نمذجة حجم المطالبة التأمينية المتوقعة ، باستخدام أسلوب المحاكاه وخوارزميتين هما: خوارزمية تعظيم التوقع Expectation Maximization (EM) Algorithm وخوارزمية تقدير بايز المحسن التقريبي The Rough-Enhanced-Bayes Mixture (REBMIX) algorithm. وباستخدام توزيع مستمر هو توزيع وايبل بمعلمتين 2-Parameter Weibull ، اعتمادا على أوزان خليط مختلفة وعدد مكونات مختلفة وأحجام عينات مختلفة.

الكلمات المفتاحية : توزيع وايبل ، التوزيعات المختلطة المحدودة ، خوارزمية تعظيم التوقع ، خوارزمية تقدير بايز المحسن التقريبي ، المحاكاة.



Abstract:

Continuous distributions are one of the important distributions used in estimating and predicting the expected financial losses. From here, this paper seeks to present two estimation methods for a set of identical finite mixture distributions that can be used to modeling the claim severity, using the simulation method and two algorithms: Expectation Maximization (EM) Algorithm and The Rough-Enhanced-Bayes Mixture (REBMIX) algorithm. Note that, the distribution used is a 2-Parameter Weibull distribution, depending on different mixture weights, number of different components, and different sample sizes.

Keywords: Weibull Distribution, Finite Mixture Distributions, Maximum Likelihood Estimation, Expectation Maximization Algorithm, The Rough-Enhanced-Bayes Mixture Algorithm, Simulation.

1. المقدمة Introduction:

توزيعات الخسارة طريقة رياضية لنمذجة المطالبات الفردية. هذه المطالبات عادة ما تكون غير متجانسة لكن لا يمكن فصل تأثير عدم التجانس منها. من هنا فإن استخدام التوزيعات المختلطة المحدودة توفر أسلوب احصائي يمكن الاعتماد عليه لوصف عدم التجانس غير الملاحظ في تلك البيانات. في هذه الورقة البحثية يتم عرض بعض التوزيعات الاحتمالية المرتبطة بحجم الخسارة وكيفية تركيبها أو تهذيبها Fitted باستخدام بيانات محاكاة لحجم المطالبات المشاهدة. من هنا ، تسعى هذه الورقة الى محاولة البحث عن طريقة جديدة لتقدير معالم توزيع حجم المطالبات بشكل يراعى عدم التجانس غير الملاحظ في بيانات المجتمع. ولعل الاجراء الأكثر شيوعا للوصول الى افضل تقدير لمعاملات التوزيع المختلط المحدود هو استخدام خوارزمية Expectation Maximization EM_algorithm وهو اجراء يهدف الى الحصول على اقصى قيمة للوغاريتم الامكان المتوقع.

بالاضافة الى خوارزمية تعظيم التوقع EM توجد خوارزمية أخرى تسمى خوارزمية تقدير بايز المحسن التقريبي The Rough-Enhanced-Bayes Mixture (REBMIX) algorithm والتي ظهرت على يد كل من Nagode and Fajdiga (1998) بهدف تجنب بعض العيوب التي ظهرت مع استخدام طريقة EM (Nagode, 2013). وباختصار ، فإن المشكلة تتمثل في تصميم محاكاة لمحاولة الوصول الى أفضل طريقة تقدير من بين الطريقتين المعروضتين في الورقة للتعبير عن حجم المطالبات التأمينية لشركات التأمين على الممتلكات من خلال مقارنة جودة التقديرات.

2. توزيع وايبل Weibull Distribution

ويعتبر توزيع وايبل احد اشهر توزيعات مدى الحياة والذي اقترح من قبل العالم الفيزيائي السويدي Waloddi Weibull عام 1939م (Lai & Xie, 2006). وللتوضيح ، وتكون دالة كثافة الاحتمال للمتغير العشوائى X والذي يتبع توزيع وايبل ، على الصورة:

$$f(x) = \begin{cases} \frac{\alpha}{\beta^\alpha} x^{\alpha-1} e^{-(x/\beta)^\alpha} , & x \geq 0 \\ 0 , & x < 0 \end{cases}$$

حيث α تسمى معلمة الشكل ، و β معلمة القياس حيث $\alpha, \beta > 0$.



3. التوزيعات المختلطة Mixture Distributions

بفرض أن $X = (X_1, X_2, \dots, X_i, \dots, X_L)$ ، تمثل متغير عشوائي مستمر من البعد L ، كما أن $x = (x_1, x_2, \dots, x_i, \dots, x_L)$ تمثل قيم المشاهدات لـ X . وبفرض أن دالة الكثافة الاحتمالية (pdf) للنموذج المختلط يمكن التعبير عنها كتركيبية محدبة من عدد K من دوال الكثافة الاحتمالية الفردية (Zhang & Huang, 2015) (Volodymyr & Ranjan, 2010) ، على الصورة:

$$f(x; \theta) = \sum_{k=1}^K w_k g_k(x; \theta_k) \quad , \quad w \geq 0 \quad , \quad i \in \{1, 2, \dots, k\} \quad , \quad \sum_{k=1}^K w_k = 1$$

حيث تمثل $g_k(x; \theta_k)$ دالة الكثافة الاحتمالية للمكون رقم k ، و w_k نسبة المكون ، كما ان $\theta = (w_1, w_2, \dots, w_k, \theta_1, \theta_2, \dots, \theta_k)$ تعبر عن مجموعة المعلمات ، و $f(x; \theta)$ تمثل دالة الكثافة الاحتمالية للخليط الناتج من مجموعة من الكثافات الاحتمالية الفردية $g_k(x; \theta_k)$.

4. تقدير نماذج الخليط المحدود Estimation in Finite Mixture Models

في هذه الدراسة سوف نتناول خوارزمتي تقدير هما: خوارزمية تعظيم التوقع EM Algorithm وخوارزمية تقدير باير المحسن التقريبي هي REBMIX Algorithm.

4.1 خوارزمية تعظيم التوقع EM Algorithm

تمثل خوارزمية تعظيم التوقع (EM) طريقة عامة لإيجاد مقدرات الإمكان الأعظم في حال وجود قيم مفقودة Missing Values أو متغيرات كامنة Latent Variable (Filho, 2008). حيث في كثير من الأحيان نجد أن البيانات لا تعطينا صورة كاملة حول الظاهرة وبالتالي تقوم EM بتعظيم قيمة الاحتمال بشكل تكرارى عوضاً عن استخدام القيم المشاهدة للوغاريتم دالة الإمكان. من خلال خطوتين الأولى **E-Step**: وفيها يتم الحصول على القيمة المتوقعة لمعادلة الامكان حيث يتم اخذ توقع لوغاريتم الامكان بهدف الحصول على تقديرات متوسطة للقيم المفقودة $D^{(Miss)}$. وبافتراض أن $Q(\theta)$ ترمز الى توقع دالة الامكان الخاص بقيم $D^{(Miss)}$ حيث:

$$Q(\theta) = E_{D^{(Miss)}|p^{(obs), \theta}} [LL(\theta)]$$

مما سبق يتبين أن هذا التوقع مشروط بكل من $D^{(obs)}$ ، θ حيث تعبر $D^{(obs)}$ عن القيم المشاهدة لذا يتم التعامل معها هنا كثوابت وليست متغيرات.

اما المرحلة أو الخطوة الثانية **M-Step**: فتعتمد على استخدام طريقة MLE ، حيث يتم التعويض عن لوغاريتم الامكان بالتوقع ، على الصورة أى:

$$\hat{\theta} = \arg \max_{\theta} Q(\theta)$$

بفرض وجود عدد k من مكونات الخليط من التوزيعات ذات الكثافات الاحتمالية

$$g_1(x; \theta_1), \dots, g_k(x; \theta_k)$$

وبافتراض أن التوزيع احادى المتغير Univariate distribution وعليه فإن دالة كثافة الاحتمال للخليط هي (Hesse, Holtackers, & Heskes, 2006):

$$f(x; \theta) = \sum_{k=1}^K w_k g_k(x; \theta_k)$$

وباستخدام خوارزمية EM لتقدير المعلمات وفقاً لأكبر توقع محلي متوقع على مرحلتين: بالنسبة للخطوة الأولى ، يتم حساب التوقع وفقاً للمعادلة:

$$Q(\theta_1, \dots, \theta_K) = \sum_{i=1}^n \left[\sum_{k=1}^K E[\Delta_{i,k} | X, \theta_1, \dots, \theta_K] \times \log(w_k g_k(x_i; \theta_k)) \right]$$

وحيث أن $\Delta_{i,k}$ تساوى "1" فى حال كانت المشاهدة رقم i تنتمى للمكون k و "0" اذا كانت لا تنتمى ، فإن:

$$E[\Delta_{i,k} | X, \theta_1, \dots, \theta_K] = 0 \times P(\Delta_{i,k} = 0 | X, \theta_1, \dots, \theta_K) + 1 \times P(\Delta_{i,k} = 1 | X, \theta_1, \dots, \theta_K) = P(\Delta_{i,k} = 1 | X, \theta_1, \dots, \theta_K)$$

وباستخدام قاعدة بايز للحصول على الاحتمال البعدى ، نجد أن:

$$P(\Delta_{i,k} = 1 | X, \theta_1, \dots, \theta_K) = \frac{P(X, \theta_1, \dots, \theta_K, \Delta_{i,k} = 1)}{P(X; \theta_1, \dots, \theta_K)} = \frac{P(X, \theta_1, \dots, \theta_K | \Delta_{i,k} = 1) P(\Delta_{i,k} = 1)}{\sum_{k'=1}^K P(X, \theta_1, \dots, \theta_K | \Delta_{i,k'} = 1) P(\Delta_{i,k'} = 1)}$$

حيث قيمة الاحتمال الهامشى The marginal probability فى المقام على الصورة:

$$P(X; \theta_1, \dots, \theta_K) = \sum_{k=1}^K w_k g_k(x_i, \theta_k)$$

وبافتراض أن المقدار $E[\Delta_{i,k} | X, \theta_1, \dots, \theta_K]$ يعبر عن Responsibility للقيم x_i ويرمز له بالرمز $\hat{\gamma}_{i,k}$ (Ng & et al, 2019) ، حيث:

$$\hat{\gamma}_{i,k} = \frac{\hat{w}_k g_k(x_i, \hat{\theta}_k)}{g(x_i, \hat{\theta}_k)} = \frac{\hat{w}_k g_k(x_i, \hat{\theta}_k)}{\sum_{k=1}^K \hat{w}_k g_k(x_i, \hat{\theta}_k)}$$

من هنا يمكن إعادة حساب التوقع فى المعادلة على الصورة:

$$Q(\theta_1, \dots, \theta_K) = \sum_{i=1}^n \left[\sum_{k=1}^K \hat{\gamma}_{i,k} \log(w_k g_k(x_i; \theta_k)) \right]$$

وبتوزيع اللوغاريتم على المقدار $w_k g_k(x_i; \theta_k)$ يمكن اعادة تبسيط المعادلة السابقة على الصورة:

$$Q(\theta_1, \dots, \theta_K) = \sum_{i=1}^n \left[\sum_{k=1}^K \hat{\gamma}_{i,k} \log w_k + \hat{\gamma}_{i,k} \log(g_k(x_i; \theta_k)) \right]$$

اما الخطوة الثانية والتي يتم فيها محاولة تعظيم خوارزمية التوقع للحصول على أقصى قيمة محلية ممكنة (Ghojogh & et al., 2019) ، من خلال العلاقة:

$$\hat{\theta}_k, \hat{w}_k = \arg \max_{\theta_k, w_k} Q(\theta_1, \dots, \theta_K, w_1, \dots, w_k) \quad , \quad \sum_{k=1}^K w_k = 1$$

وبإضافة معامل لاجرانج ، يمكن اعادة كتابة لوغاريتم دالة الامكان ليصبح على النحو التالى:



$$LL(\theta_1, \dots, \theta_k, w_1, \dots, w_k) = Q(\theta_1, \dots, \theta_k, w_1, \dots, w_k) - \alpha \left(\sum_{k=1}^K w_k - 1 \right) = \sum_{i=1}^n \sum_{k=1}^K [\hat{\gamma}_{i,k} \log w_k + \hat{\gamma}_{i,k} \log g_k(x_i; \theta_k)] - \alpha \left(\sum_{k=1}^K w_k - 1 \right)$$

وباستخدام المشتقة الأولى ومساواتها بالصفر يمكن ايجاد معلمة التوزيع للمكون k:

$$\frac{\partial LL}{\partial \theta_k} = \sum_{i=1}^n \frac{\hat{\gamma}_{i,k}}{g_k(x_i; \theta_k)} \cdot \frac{\partial g_k(x_i; \theta_k)}{\partial \theta_k} \stackrel{set}{=} 0$$

بالمثل يمكن ايجاد معلمة الخط للمكون رقم k على النحو التالي:

$$\frac{\partial LL}{\partial w_k} = \sum_{i=1}^n \frac{\hat{\gamma}_{i,k}}{w_k} - \alpha \stackrel{set}{=} 0 \Rightarrow w_k = \frac{1}{\alpha} \sum_{i=1}^n \hat{\gamma}_{i,k}$$

كذلك فإن:

$$\frac{\partial LL}{\partial \alpha} = \sum_{k=1}^K w_k - 1 \stackrel{set}{=} 0 \Rightarrow \sum_{i=1}^n w_k = 1$$

$$\sum_{k=1}^K \frac{1}{\alpha} \sum_{i=1}^n \hat{\gamma}_{i,k} = 1 \Rightarrow \alpha = \sum_{i=1}^n \sum_{k=1}^K \hat{\gamma}_{i,k}$$

وبالتعويض في المعادلة نجد أن:

$$\hat{w}_k = \frac{\sum_{i=1}^n \hat{\gamma}_{i,k}}{\sum_{i=1}^n \sum_{k=1}^K \hat{\gamma}_{i,k}}$$

ويحل المعادلات السابقة بصورة تكرارية يمكن الحصول على تقديرات للمعلمات $\hat{\theta}_k, \hat{w}_k$.

4.2 خوارزمية REBMIX:

ان المنهج الكلاسيكي في بناء الخليط المحدود يعتمد على استخدام خوارزمية EM في حل معادلة الامكان ، وبالتالي يمكن تقدير جميع المعلمات غير المعروفة في نموذج الخليط بصورة تكرارية وبالتالي تضمن خوارزمية EM ان قيمة الامكان تزداد لكن هذه الزيادة تصل الى ان تكون على وتيرة واحدة أى لا يتغير تقريبا (Nagode & Fajdiga, 2011). ان خوارزمية REBMIX تحاول معالجة مشكلة الرتابة التي تظهر مع استخدام خوارزمية EM في التقدير وبالتالي فهي تمثل اجراء عددي تكرارى يحتوى على سبع خطوات يجب اتباعها عند بناء النموذج هذه الخطوات تتمثل في:

1) المعالجة المسبقة للمشاهدات Preprocessing of observations

الخطوة الأولى من خطوات بناء الخوارزمية وذلك عن طريق اجراء تقدير للكثافة التجريبية لمجموعة البيانات (Panić & at el., 2020). وباستخدام المدرج التكرارى يتم تجزئة عدد المشاهدات الإجمالى n والذي يمثل اجمالى المشاهدات العددية المستقلة الى عدد محدود من الأجزاء bins تمثل كل منها عمود من أعمدة المدرج التكرارى تتميز بأنها غير متداخلة ومتساوية الحجم وموزعة بانتظام (Nagode, 2013). وبافتراض ان متوسطات هذه المجموعات bins y_j يمكن حسابها عن طريق المعادلة (Nagode & Fajdiga, 2011):

$$y_j = y_0 + \text{'An arbitrary integer'} \times h$$

ان الكسر Fraction في المشاهدات C_i والذي يقع في الحجم R_i يخرج من العد حيث $i=1,2,\dots,c$ ، و y_0 يرمز الى الأصل الحكمي Arbitrary origin وبيين c العدد الاجمالي للأعمدة داخل المدرج التكرارى.

وتتحدد طول فئة المدرج التكرارى بالمعادلة (Nagode , 2015):

$$h = \frac{(y_{\max} - y_{\min})}{c}$$

ويتم ايجاد الأصل y_0 من خلال المعادلة:

$$y_0 = y_{\min} + \frac{h}{2}$$

(2) اكتشاف النمط العام Global Mode Detection

يعتمد اكتشاف النمط العام أساساً لتقدير معلمة المكون التقريبية (Panić & at el., 2020).

ويتطابق النمط العام لـ y_m ، نجد أن الكثافة f_{kj} التجريبية تأخذ اقصى قيمة على الصورة:

$$m = \arg \max f_{kj} \rightarrow (y_m, f_{km})$$

وبالوصل الى الحد الأقصى المطلق والذي يحدد النمط العام ، عندها يتم وضع المشاهدات في مجموعات داخل المدرج التكرارى (Nagode, 2013) ، وبالتالي نجد أن:

$$f_{kj} = \frac{C_{kj}}{n_k} \frac{1}{h_j} \quad j=1,2,\dots,c$$

حيث يتم تهيئة التكرارات C_{kj} بصورة مبدئية على C_j ويكون عدد المشاهدات في الفئة k (Nagode , 2015)، على النحو التالى:

$$n_k = \sum_{j=1}^c C_{kj}$$

(3) تجميع المشاهدات Clustering of Observations

يعتبر تجميع المشاهدات بمثابة اجراء تكرارى لتحديد المشاهدات التى تنتمى الى مكون معين وليكن k . وحيث انه سوف يتم التركيز هنا حول النماذج وحيدة المتغيرات فإن الخوارزمية REBMIX تفترض فى البداية ان الخليط يتكون من مكون واحد اى أن $k=1$ وبالتالي فإن $n_1 = n$ ، $c_{kj} = c_j$ حيث $j=1,2,\dots,c$ والتكرارات المتبقية $r_j = 0$ لجميع قيم j . ويمكن حساب الانحرافات بين c_{kj} وتكرارات المكون التنبؤية باستخدام منهج المدرج التكرارى على الصورة:

$$e_{kj} = c_{kj} - n_k f(y_j | \theta_k) h_j$$



وتحسب الانحرافات النسبية للملاحظات على الصورة:

$$\varepsilon_{kj} = \frac{e_{kj}}{c_{kj}}$$

ويمكن فصل كل من مجموع الانحرافات الموجبة e_{kp} ومجموع الانحرافات السالبة e_{kn} كما يلي:

$$e_{kp} = \sum_{j=1, e_{kj} > 0}^c e_{kj}, e_{kn} = \sum_{j=1, e_{kj} < 0}^c e_{kj}$$

وبنفس الطريقة ، يمكن حساب الانحرافات النسبية الموجبة على النحو التالي:

$$D_k = e_{kp} / n_k$$

حيث D_k تنحصر نتائجها بين الصفر والواحد الصحيح.

4) تقدير معلمة المكون التقريبية Rough Component Parameter Estimation

في هذه الخطوة يتم استخراج العناصر المحيطة للنمط العام أولاً ، والتي من المفترض أن يكون هناك مكون واحد على الأقل في المنطقة المجاورة له (Nagode & Fajdiga, 2006). وبالتالي فإنه يمكن ضمان الاستخلاص الأمثل للملاحظات التي تنتمي الى المكون رقم k من خلال القيود التي تمنع المكون من التدفق بعيدا عن النمط العام ، والتي من المفترض أن يكون هناك مكون واحد على الأقل في المنطقة المجاورة له. ويضمن القيد الأول مساواة كثافات الاحتمال عند y_m ، حيث:

$$f_{km} = f(y = y_m | \theta_k) = f_{k \max}$$

اما القيد الثاني فيجعل النمط العام لكثافة المكون يتطابق مع y_m من خلال ايجاد المشتقة الأولى لـ $f(y = y_m | \theta_k)$ ومساواتها بالصفر على النحو التالي:

$$\frac{\partial f(y = y_m | \theta_k)}{\partial y} = 0$$

ويمكن ايجاد المعلمات لكل من التوزيعات: الطبيعي والطبيعي اللوغاريتمي وواييل احادية المتغيرات (Nagode & Fajdiga, 2006)، على النحو التالي.

$$\mu_k = y_m , \quad \sigma_k = 1 / f_{km} \sqrt{2\pi}$$

بالمثل ، نجد أن معلمات المكون الطبيعي اللوغاريتمي تكون على الصورة:

$$\mu_k = \ln(y_m) + \sigma_k^2 , \quad f(\sigma_k) = f_{km} y_m \sigma_k \sqrt{2\pi} - e^{-\frac{\sigma_k^2}{2}} = 0$$

واخيراً ، فمعلمات مكون واييل تكون على الصورة:

$$f(\alpha_k) = f_{km} y_m - (\alpha_k - 1) e^{-\frac{\alpha_k - 1}{\alpha_k}} = 0 , \quad \beta_k = y_m (\alpha_k - 1 / \alpha_k)^{-\frac{1}{\alpha_k}} + \sigma_k^2 , \quad \alpha_k > 1$$

5) تقدير معلمة المكون المحسنة Enhanced Component Parameter Estimation

للحصول على معلمات المكون المحسنة ، يتم استخدام طريقة الامكان الأعظم. وبتطبيق مدخل المدرج التكرارى ، يمكن ايجاد معلمات المكون المحسنة والذي يتبع التوزيع الطبيعي على الصورة:

$$\mu_k = \frac{1}{n_k} \sum_{j=1}^c C_{kj} y_j, \quad \sigma_k^2 = \frac{1}{n_k} \sum_{j=1}^c C_{kj} y_j^2 - \mu_k^2$$

بالمثل ، يمكن تحسين معلمة المكون الذى يتبع التوزيع الطبيعي اللوغاريتمى على الصورة:

$$\mu_k = \frac{1}{n_k} \sum_{j=1}^c C_{kj} \ln(y_j) \quad , \quad \sigma_k^2 = \frac{1}{n_k} \sum_{j=1}^c C_{kj} \ln(y_j)^2 - \mu_k^2$$

وأخيرا ، يمكن تحسين معلمة المكون الذى يتبع توزيع وايبل على الصورة:

$$f(\alpha_k) = \frac{1}{\alpha_k} + \frac{1}{n_k} \sum_{j=1}^c C_{kj} \ln(y_j) - \frac{\sum_{j=1}^c C_{kj} y_j^{\alpha_k} \ln(y_j)}{\sum_{j=1}^c C_{kj} y_j^{\alpha_k}} = 0$$

$$\beta_k^{\alpha_k} = \frac{1}{n_k} \sum_{j=1}^c C_{kj} y_j^{\alpha_k}$$

6) حساب العزم الأول والثانى First and second Moment Calculation

باستخدام العزم الأول والثانى يمكن ايجاد متوسط وتباين المكون الذى يتبع التوزيع الطبيعي (Nagode, 2013) ، على النحو التالى:

$$m_k = \mu_k \quad , \quad Var_k = \sigma_k^2 + \mu_k^2$$

بالمثل ، يمكن ايجاد متوسط وتباين المكون الذى يتبع التوزيع الطبيعي اللوغاريتمى على الصورة:

$$m_k = e^{\mu_k + \frac{\sigma_k^2}{2}} \quad , \quad Var_k = e^{2\mu_k + 2\sigma_k^2}$$

7) تصنيف بايز للمشاهدات المتبقية Bayes Classification of the Remaining Observations

بزيادة عدد المكونات ، ينخفض عدد المشاهدات المتبقية. وعندما يصل الوزن النسبى للمكون الى اقل وزن نسبى (Nagode & Fajdiga, 2011) ، أى:

$$w_k \leq w_{\min}$$

يتم افتراض أن المشاهدات المتبقية تنتمى الى الفئة الحالية ولا يتم تكوين فئات جديدة. ايضا فهناك لاقعة ارتباط بين اقل وزن نسبى و D_{\min} . فكلما زاد مؤشر المكون رقم K فإن كل من عدد المكونات ومجموع الانحرافات النسبية الموجبة يزداد ايضا.



$$D = \sum_{k=1}^K w_k D_k \geq KD_{\min}$$

وإذا وصل الوزن النسبي للمكون الى اجمالى الانحرافات النسبية بمقدار $2kD_{\min}$ تتوقف الخوارزمية .REBMIX

$$w_{\min} = 2kD_{\min}$$

ويتم تصنيف المشاهدات المتبقية اعتمادا على قاعدة بايز ، كما يلي:

$$w_k = w_k + \frac{C_{kj}}{n} , \quad m_k = m_k + \frac{C_{kj}(y_j - m_k)}{nw_k}$$

$$Var_k = Var_k + \frac{C_{kj}(y_j^2 - Var_k)}{nw_k}$$

حيث يتم اضافة C_{kj} الى الفئة k والوزن النسبي للمكون ، ويتم اعادة حساب المتوسط والتباين للمكون. بمجرد معالجة جميع المجموعات والتي يرمز لها بالرمز C او جميع المشاهدات n ، يتم الحصول على معلمات الخليط عن طريق اعادة حساب العزم الأول والثانى لمكونات الخليط.

5. المحاكاة:

فى هذه الدراسة تم استخدام كل من لوغاريتم الامكان ومعيار المعلومات البيزى كمعيارى مقارنة رئيسيين حيث كلما كانت قيمة لوغاريتم الامكان المطلقة اكبر ما يمكن دل ذلك على كفاءة المقدرات ، أيضا فإن معيار المعلومات البيزى (Bayesian information criterion (BIC) كلما كانت قيمته اعلى دل ذلك على جودة التقديرات، كذلك سوف يتم استخدام خوارزمية EM و REBMIX ومن ثم مقارنة نتائج التقدير وباستخدام حزم برنامج R باصدار R i386 4.0.3.

6.1 تصميم المحاكاه:

تمت عملية المحاكاة باستخدام بيانات افتراضية من أحجام مختلفة من العينات وهى 500 و 1500 و 2500 مفردة بنسب تمثيل مختلفة. ويتم تكوين توزيعات مختلطة محدودة متماثلة Identical Finite Mixtue Distributions من عدد من المكونات k مفترضة للدراسة ، حيث k=2,3,4. ايضا يمكن عرض توزيعات الخليط التى سيتم بنائها ومحاكاتها وفقا للجدول:

جدول (1): توزيعات الخليط المولدة لعملية المحاكاه بالنسبة لتوزيع وايبل

المعلمات	عدد المكونات
$w, \alpha_{w1}, \beta_{w1}, \alpha_{w2}, \beta_{w2}$	2
$w_1, w_2, \alpha_{w1}, \beta_{w1}, \alpha_{w2}, \beta_{w2}, \alpha_{w3}, \beta_{w3}$	3
$w_1, w_2, w_3, \alpha_{w1}, \beta_{w1}, \alpha_{w2}, \beta_{w2}, \alpha_{w3}, \beta_{w3}, \alpha_{w4}, \beta_{w4}$	4

أيضا تتم عملية المحاكاه مع افتراض أن اوزان الخليط على ثلاث حالات وفقا للجدول التالي:

جدول (2): اوزان الخليط الخاصة بنسب المكونات

متفاوتة	متساوية	متقاربة
$w_1 = 0.2, w_2 = 0.8$	$w_1 = w_2 = 0.5$	$w_1 = 0.4, w_2 = 0.6$
$w_1 = 0.1, w_2 = 0.3, w_3 = 0.6$	$w_1 = w_2 = w_3 = 0.333$	$w_1 = 0.25, w_2 = 0.3, w_3 = 0.45$
$w_1 = 0.1, w_2 = 0.3, w_3 = 0.5, w_4 = 0.1$	$w_1 = w_2 = w_3 = w_4 = 0.25$	$w_1 = 0.2, w_2 = 0.3, w_3 = 0.3, w_4 = 0.2$

كذلك فقد تم افتراض قيماً تقريبية للمعاملات الحقيقية من خلال النظر الى طبيعة بيانات

المطالبة التأمينية للبيانات الفعلية المتاحة ، وفقا للجدول التالي:

جدول (3): القيم الفعلية للمعاملات لتوزيعات الخليط المولدة لعملية المحاكاه والخاصة لتوزيع وايبل

توزيعات الخليط	معلمات المكونات
Weibull(2)	$\alpha_{w1} = 0.72738, \beta_{w1} = 409.1349, \alpha_{w2} = 0.60222, \beta_{w2} = 1335.6705$
Weibull (3)	$\alpha_{w1} = 0.5426926, \beta_{w1} = 86.28743, \alpha_{w2} = 0.7855334, \beta_{w2} = 609.64774, \alpha_{w3} = 0.5316595, \beta_{w3} = 1001.696$
Weibull(4)	$\alpha_{w1} = 0.511479, \beta_{w1} = 156.2808, \alpha_{w2} = 0.77344, \beta_{w2} = 559.484, \alpha_{w3} = 0.52639, \beta_{w3} = 656.8403, \alpha_{w4} = 0.62661, \beta_{w4} = 1683.936$

6.2 نتائج المحاكاه لتوزيعات وايبل الممثلة لحجم المطالبة:

تتمثل توزيعات حجم المطالبة في التوزيعات شديدة الالتواء ناحية اليمين والتي من اشهرها توزيع وايبل. وقد تم اثناء المحاكاه فرض قيد على عدد التكرارات بحيث يكون عدد التكرارات مساوى لحجم العينة كما تم التحقق من التقارب بوضع قيد على عملية التقارب بحيث يتوقف الاختبار اذا كانت الفروق بين التقديرات المتتالية اقل من 10^{-4} ، كما أن الطريقة المتبعة في مرحلة ما قبل المعالجة بالنسبة لخوارزمية REBMIX اعتمادا على مدخل المدرج التكرارى ، ويمكن عرض النتائج وفقا للقيم المرصودة بالجدول التالية:

جدول (4): نتائج المحاكاه لتقدير خليط من توزيع وايبل بحجم عينة (500) مفردة

الخليط	K	خوارزمية التقدير	المعاملات الفعلية	التقديرات (اوزان متفاوتة)	LL	BIC	التقديرات (اوزان متساوية)	LL	BIC	التقديرات (اوزان متقاربة)	LL	BIC	
weibull	2	EM	w_1	$w_1 = 0.8, w_2 = 0.2$	-3690.982	7413.038	$w_1 = w_2 = 0.5$	-3818.373	7667.818	$w_1 = 0.6, w_2 = 0.4$	-3816.375	7663.823	
			$\alpha_{w1} = 0.72738$										
			$\beta_{w1} = 409.1349$										
			$\alpha_{w2} = 0.60222$										
			$\beta_{w2} = 1335.6705$										
			w_1	$w_1 = 0.8, w_2 = 0.2$	-370.597	7552.266	$w_1 = w_2 = 0.5$	-3939.075	7909.222	$w_1 = 0.6, w_2 = 0.4$	-3936.678	7904.429	
	$\alpha_{w1} = 0.72738$												
	$\beta_{w1} = 409.1349$												
	$\alpha_{w2} = 0.60222$												
	$\beta_{w2} = 1335.6705$												
	3												



BIC	LL	التقديرات (اوزان متقاربة)	BIC	LL	التقديرات (اوزان متساوية)	BIC	LL	التقديرات (اوزان متفاوتة)	المعطيات الفعيلة	خوارزمية التقدير	K	الخليط
6808.749	-3379.516	0.25983	6987.111	-3468.697	0.30428	6538.795	-3244.539	0.39543	w_1	EM		
		0.36939			0.49753			0.43523	w_2			
		0.48393			0.43373			0.50767	$\alpha_{w_1} = 0.5426926$			
		15.78208			78.3086			29.4079	$\beta_{w_1} = 86.28743$			
		0.84992			0.61829			0.81224	$\alpha_{w_2} = 0.7855334$			
		360.6678			494.1171			512.442	$\beta_{w_2} = 609.64774$			
		0.54188			0.42451			0.43696	$\alpha_{w_3} = 0.5316595$			
		868.455			768.722			589.981	$\beta_{w_3} = 1001.696$			
7921.197	-3935.74	0.53188	8194.755	-4072.519	0.51014	8184.564	-4067.424	0.49703	w_1	REBMIX		
		0.05072			0.05028			0.04115	w_2			
		1.18313			1.14737			1.24447	$\alpha_{w_1} = 0.5426926$			
		975.591			1138.196			873.430	$\beta_{w_1} = 86.28743$			
		0.67808			2.51753			2.82604	$\alpha_{w_2} = 0.7855334$			
		3763.205			12734.66			7418.648	$\beta_{w_2} = 609.64774$			
		1.70386			1.70386			1.70386	$\alpha_{w_3} = 0.5316595$			
		670.456			768.7402			655.2182	$\beta_{w_3} = 1001.696$			
$w_1 = 0.2, w_2 = 0.3, w_3 = 0.3, w_4 = 0.2$		$w_1 = w_2 = w_3 = w_4 = 0.25$		$w_1 = 0.1, w_2 = 0.5, w_3 = 0.3, w_4 = 0.1$								
7403.422	-3667.531	0.2783	7356.897	-3644.268	0.29642	7503.713	-3717.676	0.182522	w_1	EM		
		0.30292			0.32052			0.469796	w_2			
		0.27346			0.19091			0.074509	w_3			
		0.555786			0.44685			0.570702	$\alpha_{w_1} = 0.511479$			
		33.34342			148.5197			32.410498	$\beta_{w_1} = 156.2808$			
		1.30302			0.642517			1.258008	$\alpha_{w_2} = 0.77344$			
		362.8535			414.4967			426.83012	$\beta_{w_2} = 559.484$			
		0.9543			0.563712			5.860645	$\alpha_{w_3} = 0.52639$			
		1566.8228			737.433			2331.1297	$\beta_{w_3} = 656.8403$			
		0.53844			0.54498			0.568945	$\alpha_{w_4} = 0.62661$			
		1701.6586			1498.702			1328.35796	$\beta_{w_4} = 1683.936$			
8190.342	-4060.99	0.48906	7889.355	-3910.497	0.474068	7805.688	-3868.664	0.941526	w_1	REBMIX		
		0.05028			0.02787			0.0281856	w_2			
		0.02689			0.00373			0.004005	w_3			
		1.23585			1.258504			1.067101	$\alpha_{w_1} = 0.511479$			
		1008.814			1113.868			746.9577	$\beta_{w_1} = 156.2808$			
		2.37839			3.579439			10.14989	$\alpha_{w_2} = 0.77344$			
		7353.172			10009.04			8442.077	$\beta_{w_2} = 559.484$			
		9.0626			58.08894			25.7953	$\alpha_{w_3} = 0.52639$			
		33489.67			32997.57			12348.25	$\beta_{w_3} = 656.8403$			
		1.703863			1.001419			8.61342	$\alpha_{w_4} = 0.62661$			
		578.814			702.9292			33514.35	$\beta_{w_4} = 1683.936$			

جدول (5): نتائج المحاكاه لتقدير خليط من توزيع وايبل بحجم عينة (1500) مفردة

BIC	LL	التقديرات (اوزان متقاربة)	BIC	LL	التقديرات (اوزان متساوية)	BIC	LL	التقديرات (اوزان متفاوتة)	المعاملات الفعلية	خوارزمية التقدير	K	الخليط
$w_1 = 0.6, w_2 = 0.4$		$w_1 = w_2 = 0.5$			$w_1 = 0.8, w_2 = 0.2$							
22791.047	-11377.241	0.55317	23228.223	-11595.829	0.48071	22104.278	-11033.856	0.85671	w_1	EM	2	Weibull
		0.69381			0.66577			0.66061	$\alpha_{w_1} = 0.72738$			
		374.939			366.225			401.154	$\beta_{w_1} = 409.1349$			
		0.50494			0.518701			0.48294	$\alpha_{w_2} = 0.60222$			
		1080.784			1243.275			1506.704	$\beta_{w_2} = 1335.6705$			
23750.38	-11856.91	0.92599	24212.03	-12087.73	0.90656	23842.34	-11902.89	0.96226	w_1	REBMIX		
		1.118423			1.114399			1.14091	$\alpha_{w_1} = 0.72738$			
		772.4333			815.7947			733.454	$\beta_{w_1} = 409.1349$			
		1.036263			1.141252			3.21113	$\alpha_{w_2} = 0.60222$			
		9066.776			9730.179			10074.45	$\beta_{w_2} = 1335.6705$			
$w_1 = 0.4, w_2 = 0.35, w_3 = 0.25$		$w_1 = w_2 = w_3 = 0.333$			$w_1 = 0.6, w_2 = 0.3, w_3 = 0.1$							
20666.7	-10304.097	0.06008	21151.447	-10546.471	0.120356	19000.993	-9471.244	0.64854	w_1	EM	3	
		0.63967			0.595902			0.328308	w_2			
		0.937253			0.59893			0.46014	$\alpha_{w_1} = 0.5426926$			
		9.730003			25.0848			5937188	$\beta_{w_1} = 86.28743$			
		0.571487			0.57837			0.75923	$\alpha_{w_2} = 0.7855334$			
		369.6408			474.845			696.6726	$\beta_{w_2} = 609.64774$			
		0.348071			0.35988			0.596385	$\alpha_{w_3} = 0.5316595$			
		350.67748			494.5011			0.00668	$\beta_{w_3} = 1001.696$			
24956.06	-12448.77	0.531974	24442.76	-12192.13	0.552775	23569.91	-11755.7	0.482901	w_1	REBMIX		
		0.050581			0.055568			0.028813	w_2			
		1.194232			1.171785			1.24847	$\alpha_{w_1} = 0.5426926$			
		1107.922			1210.845			960.134	$\beta_{w_1} = 86.28743$			
		2.285546			0.65875			0.538084	$\alpha_{w_2} = 0.7855334$			
		10598.19			6943.286			3934.514	$\beta_{w_2} = 609.64774$			
		1.703863			1.703863			1.703863	$\alpha_{w_3} = 0.5316595$			
		755.6009			796.444			729.4766	$\beta_{w_3} = 1001.696$			
$w_1 = 0.2, w_2 = 0.3, w_3 = 0.3, w_4 = 0.2$		$w_1 = w_2 = w_3 = w_4 = 0.25$			$w_1 = 0.1, w_2 = 0.5, w_3 = 0.3, w_4 = 0.1$							
22217.665	-11068.61	0.309723	22223.125	-11071.34	0.283224	22299.714	-11109.635	0.294332	w_1	EM	4	
		0.307399			0.319188			0.289847	w_2			
		0.205029			0.195475			0.343583	w_3			
		0.4107735			0.397166			0.44184	$\alpha_{w_1} = 0.511479$			
		104.81245			124.6144			93.84846	$\beta_{w_1} = 156.2808$			
		0.6650597			0.57044			0.889702	$\alpha_{w_2} = 0.77344$			
		413.21926			458.4045			344.29452	$\beta_{w_2} = 559.484$			
		0.7012848			0.612386			0.802446	$\alpha_{w_3} = 0.52639$			
		1298.6033			793.2208			1334.5514	$\beta_{w_3} = 656.8403$			
		0.5094112			0.522664			0.5201218	$\alpha_{w_4} = 0.62661$			
		1989.6697			2011.473			298.48	$\beta_{w_4} = 1683.936$			



BIC	LL	التقديرات (اوزان متقاربة)	BIC	LL	التقديرات (اوزان متساوية)	BIC	LL	التقديرات (اوزان متفاوتة)	المعاملات الفعلية	خوارزمية التقدير	K	الخليط
24012.61	-11966.08	0.947571	25122.54	-12521.05	0.547134	24459.22	-12189.39	0.5399099	w_1	REBMIX		
		0.007136			0.053782			0.0587055	w_2			
		0.005617			0.036418			0.0248467	w_3			
		0.942812			1.220132			1.248434	$\alpha_{w_1} = 0.511479$			
		1500.595			1011.734			931.9328	$\beta_{w_1} = 156.2808$			
		0.605169			2.207048			1.978265	$\alpha_{w_2} = 0.77344$			
		17935.96			10436.58			7052.628	$\beta_{w_2} = 559.484$			
		13.86289			5.541217			8.891712	$\alpha_{w_3} = 0.52639$			
		42549.09			43437.17			42375	$\beta_{w_3} = 656.8403$			
		2.037234			1.703863			1.703863	$\alpha_{w_4} = 0.62661$			
1272.758	597.8005	538.3963	$\beta_{w_4} = 1683.936$									

جدول (6): نتائج المحاكاه لتقدير خليط من توزيع واييل بحجم عينة (2500) مفردة

BIC	LL	التقديرات (اوزان متقاربة)	BIC	LL	التقديرات (اوزان متساوية)	BIC	LL	التقديرات (اوزان متفاوتة)	المعاملات الفعلية	خوارزمية التقدير	k	الخليط
$w_1 = 0.6, w_2 = 0.4$		$w_1 = w_2 = 0.5$				$w_1 = 0.8, w_2 = 0.2$						
38037.127	-18999.003	0.60488	38608.123	-19284.502	0.41769	36866.245	-18413.562	0.73356	w_1	EM	2	Weibull
		0.70009			0.73807			0.707042	$\alpha_{w_1} = 0.72738$			
		418.264			373.6375			391.3087	$\beta_{w_1} = 409.1349$			
		0.52446			0.538066			0.530888	$\alpha_{w_2} = 0.60222$			
		1109.089			1061.087			939.5847	$\beta_{w_2} = 1335.6705$			
40586.82	-20273.85	0.963689	40335.74	-20148.31	0.94019	37991.33	-18976.1	0.92415	w_1	REBMIX	2	Weibull
		1.11867			1.08331			1.14575	$\alpha_{w_1} = 0.72738$			
		1157.048			1109.504			550.014	$\beta_{w_1} = 409.1349$			
		2.91056			0.834924			1.15285	$\alpha_{w_2} = 0.60222$			
		10950.53			7889.52			5536.83	$\beta_{w_2} = 1335.6705$			
$w_1 = 0.4, w_2 = 0.35, w_3 = 0.25$		$w_1 = w_2 = w_3 = 0.333$				$w_1 = 0.6, w_2 = 0.3, w_3 = 0.1$						
34370.089	-17153.748	0.29773	35133.101	-17535.254	0.415011	31886.626	-15912.017	0.349702	w_1	EM	3	Weibull
		0.54011			0.513857			0.457871	w_2			
		0.446419			0.421895			0.493093	$\alpha_{w_1} = 0.5426926$			
		120.1621			357.3099			27.97724	$\beta_{w_1} = 86.28743$			
		0.563188			0.563487			0.734631	$\alpha_{w_2} = 0.7855334$			
		438.5974			360.04999			448.06445	$\beta_{w_2} = 609.64774$			
		0.349781			0.3154255			0.3848103	$\alpha_{w_3} = 0.5316595$			
		470.8009			43.60143			310.32132	$\beta_{w_3} = 1001.696$			
42138.33	-21037.87	0.436322	42549.67	-21243.54	0.447978	36870.32	-18403.86	0.602934	w_1	REBMIX	3	Weibull
		0.024578			0.026043			0.063404	w_2			
		1.215898			1.220685			1.181035	$\alpha_{w_1} = 0.5426926$			
		1796.534			1920.93			511.4924	$\beta_{w_1} = 86.28743$			
		0.561619			0.5818297			0.755605	$\alpha_{w_2} = 0.7855334$			

الخليط	k	خوارزمية التقدير	المعاملات الفعلية	التقديرات (اوزان متفاوتة)	LL	BIC	التقديرات (اوزان متساوية)	LL	BIC	التقديرات (اوزان متقاربة)	LL	BIC	
			$\beta_{w_2} = 609.64774$	2959.459			5489.268			4927.602			
			$\alpha_{w_2} = 0.5316595$	1.703863			1.703863				1.703863		
			$\beta_{w_2} = 1001.696$	319.4476			1529.321				1450.49		
										$w_1 = 0.2, w_2 = 0.3, w_3 = 0.3, w_4 = 0.2$			
										$w_1 = w_2 = w_3 = w_4 = 0.25$			
										$w_1 = 0.1, w_2 = 0.5, w_3 = 0.3, w_4 = 0.1$			
EM	4		w_1	0.23866	37073.355	-18493.645	0.214219	36886.001	-18399.973	0.352297	36851.373	-18382.654	
			w_2	0.274197			0.569459			0.339647			
			w_3	0.34328			0.136544			0.2563501			
			$\alpha_{w_1} = 0.511479$	0.822484			0.483448			0.4493912			
			$\beta_{w_1} = 156.2808$	202.303			22.75509			114.19554			
			$\alpha_{w_2} = 0.77344$	0.890822			0.773137			0.7516037			
			$\beta_{w_2} = 559.484$	1000.504			486.0808			434.28058			
			$\alpha_{w_3} = 0.52639$	0.481915			1.124921			0.7601273			
			$\beta_{w_3} = 656.8403$	500.4805			4010.5766			2114.9923			
			$\alpha_{w_4} = 0.62661$	0.380324			0.4337833			0.3768194			
			$\beta_{w_4} = 1683.936$	506.3257			145.9927			976.247			
			REBMIX	4						w_1			0.400338
w_2	0.019233	0.034132			0.0273378								
w_3	0.013866	0.022812			0.0170776								
$\alpha_{w_1} = 0.511479$	1.260678	1.231689			1.234054								
$\beta_{w_1} = 156.2808$	1702.252	1570.539			1672.359								
$\alpha_{w_2} = 0.77344$	1.766723	1.71645			2.044558								
$\beta_{w_2} = 559.484$	13900.52	12680.79			12705.5								
$\alpha_{w_3} = 0.52639$	7.881071	4.879662			6.433462								
$\beta_{w_3} = 656.8403$	127955.2	123588.5			129222.4								
$\alpha_{w_4} = 0.62661$	1.703863	1.703863			1.703863								
$\beta_{w_4} = 1683.936$	984.4584	920.3967			984.4584								

6. التعليق على نتائج المحاكاه:

ان الهدف الرئيسي للدراسة هو بناء مجموعة من التوزيعات المختلطة لنمذجة حجم الخسارة المتوقعة والتوصل الى افضل طريقة تقدير ممكنة من بين الطريقتين المقترحتين وقد توصلت المحاكاه الى الآتى:

1- المعلمات المستخرجة باستخدام خوارزمية REBMIX تعطي نتائج أفضل من خوارزمية EM فيما يتعلق بجودة التوافق ، يظهر ذلك من خلال ملاحظة الزيادة فى قيمة كل من لوغاريتم الامكان LL ومعيار المعلومات البيزى BIC.

2- كلما كانت الأوزان النسبية لمكونات الخليط متساوية أو متقاربة كلما كانت النتائج أقرب الى المعلمة الحقيقية ، والعكس صحيح ، فكلما تفاوتت أوزان الخليط كلما انخفضت معها دقة التقدير يتضح ذلك من خلال كل من قيم LL و BIC.



- 3- كلما ازدادت أحجام العينات ازداد معها قيم كل من لوغاريتم الامكان LL ومعيار المعلومات البيزي BIC ايضا يظهر الارتفاع الشديد فى النتائج لخوارزمية REBMIX وخوارزمية EM حيث يلاحظ زيادة كبيرة فى قيمتى معيارى المقارنة.
- 4- بنفس الطريقة ، فإنه بزيادة عدد المكونات تزداد قيم كل من لوغاريتم الامكان LL ومعيار المعلومات البيزي BIC.
- 5- أثناء عملية المعالجة باستخدام حزم برنامج R i386 4.0.3 لوحظ أن التقدير باستخدام خوارزمية REBMIX يعطى نتائج اسرع بكثير من استخدام خوارزمية EM.
- 6- وفقا لنتائج المحاكاه فإن افضل مزيج للبيانات محل الدراسة يعبر عن توزيع شدة أو حجم الخسارة هو توزيع وايبل بمكونين ، ويمكن الاستدلال على ذلك من قرب نتائج التقدير من المعلمات الحقيقية المفترضة.

المراجع:

- <https://ocw.mit.edu/courses/mathematics/18-443-statistics-for-applications-fall-2006/lecture-notes/lecture6.pdf>. (2020, October 14).
- Filho, I. (2008). *Mixture Models for the Analysis of Gene Expression: Integration of Multiple Experiments and Cluster Validation*. Berlin, Germany: Department of Mathematics and Computer, Free University of Berlin.
- Ghojogh, B., & et al. (2019, jan 20). Fitting A Mixture Distribution to Data: Tutorial.
- Hesse, C., Holtackers, D., & Heskes, T. (December 7-8, 2006). On the use of mixtures of Gaussians and mixtures of generalized exponentials for modelling and classification of biomedical signals. *Belgian Day on Biomedical Engineering IEEE Benelux EMBS Symposium*.
- Lai, C.-D., & Xie, M. (2006). *Stochastic Ageing and dependence for reliability*. New York, United States: Springer+Business Media Inc.
- Nagode, M. (2013). rebmix: An R Package for Continuous and Discrete Finite Mixture Models.
- Nagode, M. (2015, April). Finite Mixture Modeling via REBMIX. *Journal of Algorithms and Optimization*, 3(2).
- Nagode, M., & Fajdiga, M. (2006, April). An alternative perspective on the mixture estimation problem. *Reliability Engineering & System Safety*, 91(4).
- Nagode, M., & Fajdiga, M. (2011). The REBMIX Algorithm and the Univariate Finite Mixture Estimation. *Communications in Statistics - Theory and Methods*, 40(11).
- Ng, S., & et al. (2019). *Mixture Modelling for Medical and Health Sciences*. FL,USA: Taylor & Francis Group, Boca Raton.
- Panić, B., & at el. (2020, March). Improved Initialization of the EM Algorithm for Mixture Model Parameter Estimation. *Mathematics*, 8(3).
- Volodymyr, M., & Ranjan, M. (2010). Finite mixture models and model-based clustering. *Statistics Surveys*, 4.
- Zhang, H., & Huang, Y. (2015, March 26). Finite Mixture Models and Their Applications: A Review. *Austin Biom and Biostat*, 2(1).