

Evlerde Tüketim Ayrıştırması Probleminin İncelenmesi

Ekim 2019



EVLERDE TÜKETİM AYRIŞTIRMASI PROBLEMİNİN İNCELENMESİ

Emre ERYİĞİT^A, Rabia Şeyma YILMAZ^A, Şafak BAYKAL^A, Erman
TERCİYANLI^A






^AT4E Enerji A.Ş., Ankara

İçerik

- Çıkış Noktası
- İlgili Çalışmalar
- Ayrıştırma Modeli Çalışma Yapısı
- Önerilen Metot
- Deney Veri Seti
- Deney Sonuçları

Çıkış Noktası

Etkenler

-  ● IEC, akıllı ve ekonomik enerji kullanımının, yenilenebilir enerji kaynaklarından enerji üretiminin yanı sıra verimli enerji kullanımı ile de olacağını söylemektedir. [3]
-  ● Enerji verimliliği sadece daha az elektrik kullanımı ile değil; aynı zamanda sistemlerin ve sosyal davranışların değişmesi ile de bağlantılıdır. [3]
-  ● Pozitif davranış değişiminin ev sakinlerine evdeki cihazların ne kadar enerji kullandığını gösteren bildirimler sağlanarak başarabildiği belirtilmektedir. [4]
-  ● Cihaz bazında kullanım bilgisine dayanan enerji tüketimi stratejisi uygulayarak %9 ile %20 oranında enerji korunumunu elde edilebileceği gösterilmiştir. [5]
-  ● Cihaz kullanım kayıtları cihazların durumlarını kontrol etme ve hatalı çalışan cihazları tespit etme noktasında da faydalıdır. [6]

İlgili Çalışmalar


Cihaz Bazında Tüketim Verisi Elde Etme (Appliance Load Monitoring)

Intrusive Load Monitoring

- Her bir cihazda tüketiminin izlenip kaydedilebildiği sensörler
- Elverişsiz ve pahalı [7]

Nonintrusive Load Monitoring


- NILM
- Energy Disaggregation
- Basit donanım, karmaşık veri işleme ve analiz
- Toplam elektrik yükü ölçülür
- Cihazlara ait imzalara ulaşılır
- Cihazların ayrı ayrı verilerinin kullanan denetlenen algoritmalar
- Cihaz verisi kullanmayan denetlenmeyen algoritmalar [8, 9]




Çamaşır Makinası



Kettle



Buzdolabı



İlgili Çalışmalar

Nonintrusive Load Monitoring

Hart Metot

İlk NILM metodu

4 ana aşama:

- Edge detection: kararlı haldeki güç seviyeleri
- Gruplama: aktif ve reaktif güç değerleri
- Eşleştirme: pozitif ve negatif yöndeki benzer değerlerin eşleştirilmesi
- Etiketleme: el ile [9,10]

FHMM

Denetimsiz Öğrenme

Her bir cihaz için saklı markov model[23]

RNN

İlk derin sinir ağı mimarisi

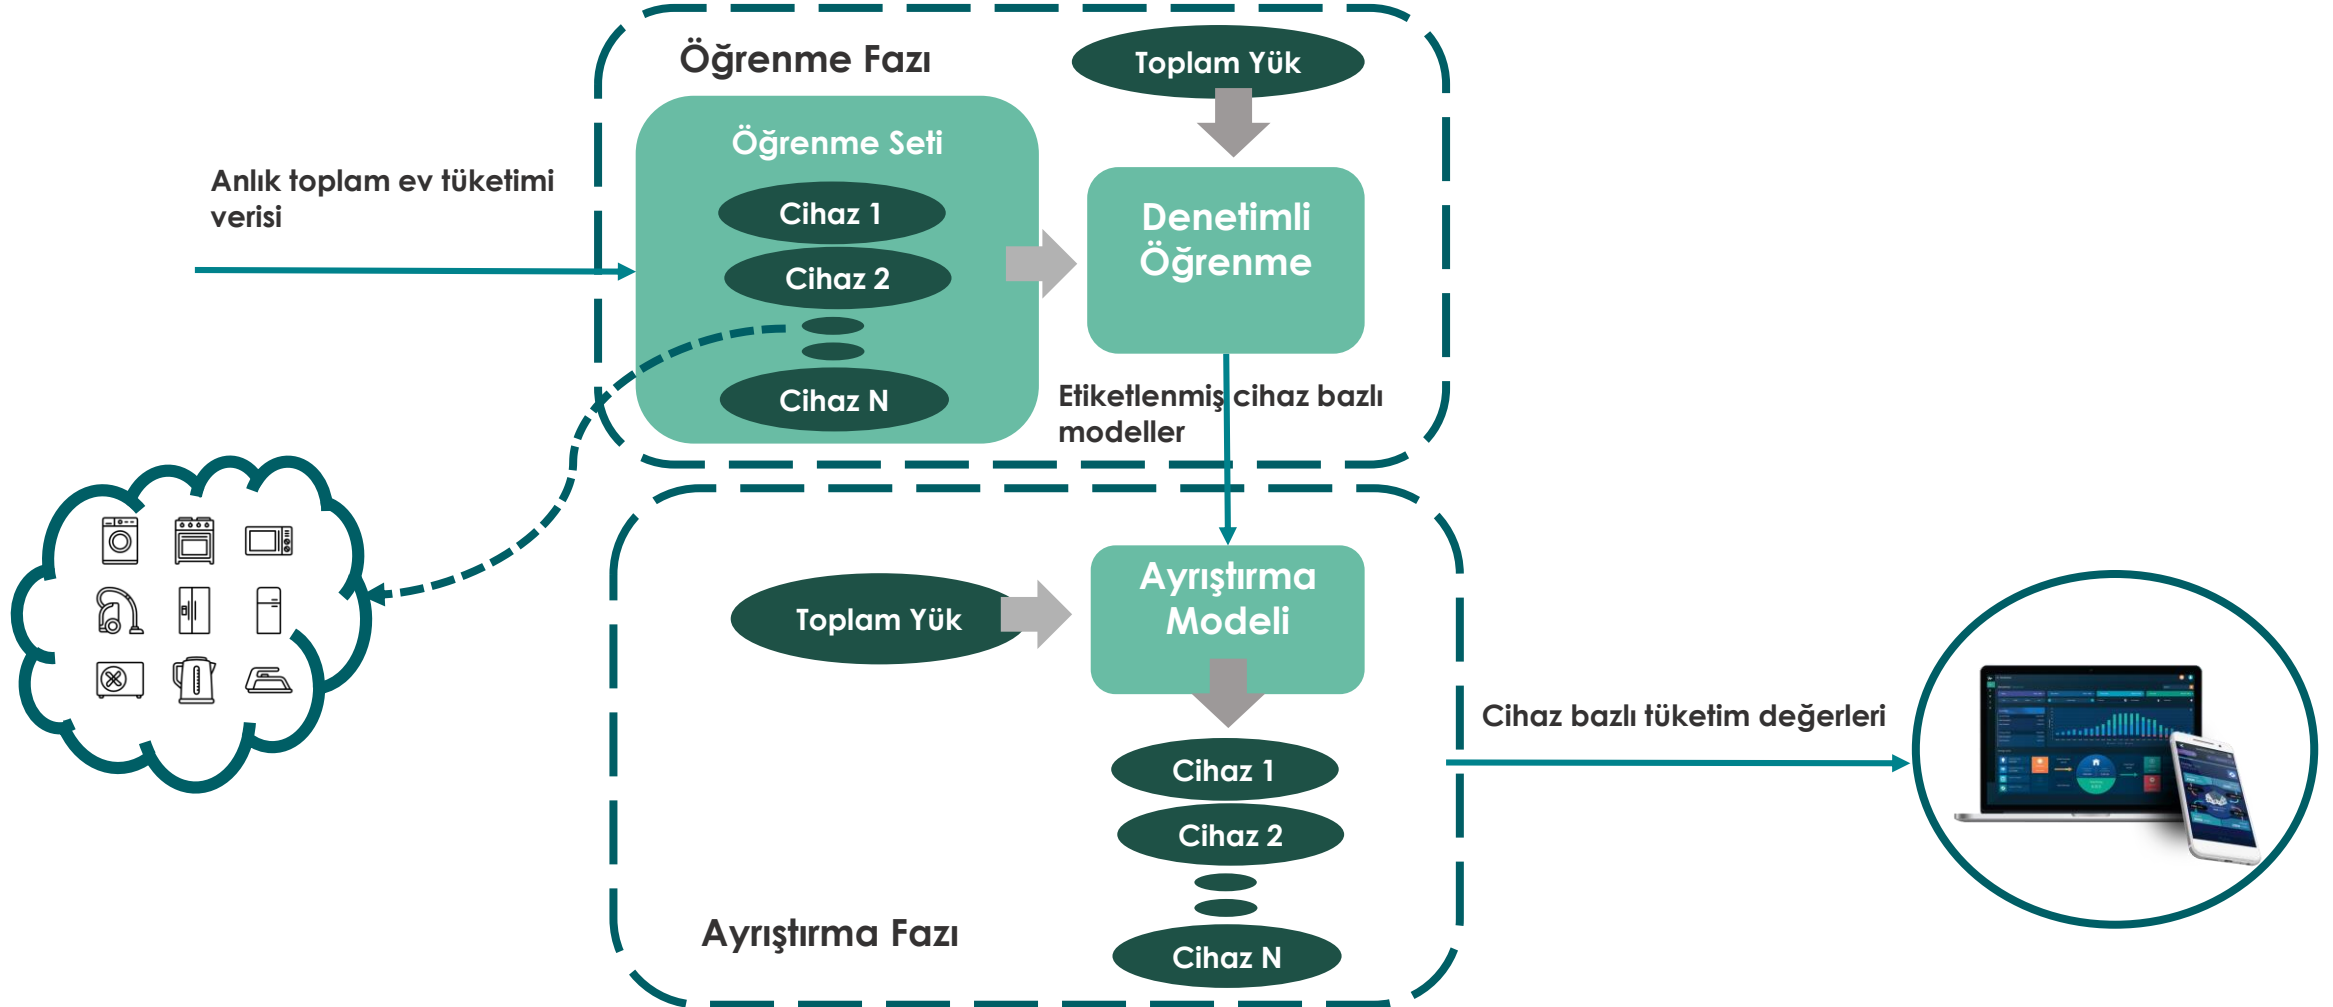
LSTM(Kısa uzun süreli bellek) [16,17,18]

Denoising Encoders

Gürültü Arındırma Otomatik Kodlayıcıları altı katmanlı uygulama[19]

Ayrıştırma Modeli Çalışma Yapısı

Denetimli Öğrenme



Önerilen Metot

Konvolüsyonel Sinir Ağı

Açık/Kapalı Durum Tahmini

Model aşağıdaki katmanlardan oluşmaktadır.

- ReLU aktivasyon fonksiyonlu dört CNN katmanı (her katmanda 2x2 filtre büyüklüğünde 32 filtre) ve “He - Xavier” başlatma [20].
- Her katmandan sonra bir toplu normalleştirme [21] katmanı.
- CNN katmanlarından sonra, biri ReLU aktivasyon fonksiyonlu, diğeri **Softmax** fonksiyonlu iki tam bağlı katman.

Kayıp fonksiyonu: kategorik-çapraz entropi

Batch büyüklüğü: 200

Adam Optimizer

Öğrenme oranı: 5e-4

Tüketim Tahmini

Model aşağıdaki katmanlardan oluşmaktadır.

- ReLU aktivasyon fonksiyonlu dört CNN katmanı (her katmanda 2x2 filtre büyüklüğünde 32 filtre) ve “He - Xavier” başlatma [20].
- Her katmandan sonra bir toplu normalleştirme [21] katmanı.
- CNN katmanlarından sonra, biri ReLU aktivasyon fonksiyonlu, diğeri **ortalama kare hata kaybı** fonksiyonlu iki tam bağlı katman.

Kayıp fonksiyonu: kategorik-çapraz entropi

Batch büyüklüğü: 200

Adam Optimizer

Öğrenme oranı: 5e-4

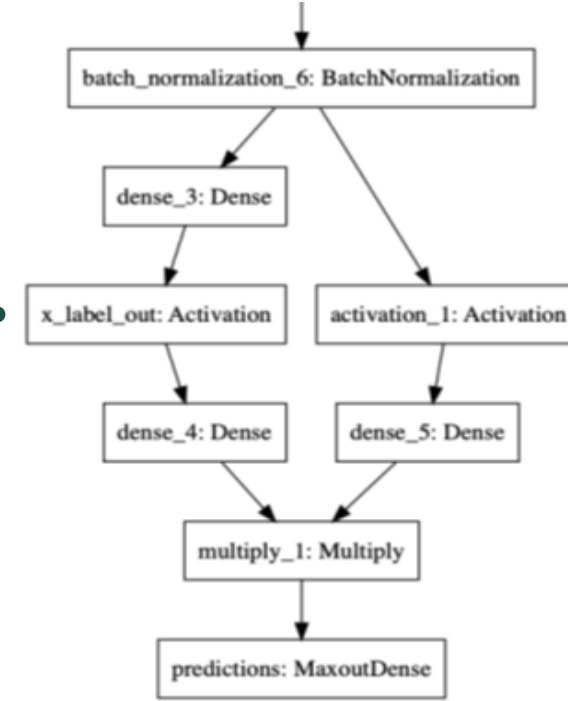
Önerilen Metot

Konvolüsyonel Sinir Ağı

Kombinasyon Modeli

Etiketleme ve tüketim tahminini içerecek şekilde model mimarisi aşağıdaki şekilde değiştirilmiştir.

- Filter boyutu 32 olan 4 konvolüsyonel katman, “He-Xavier” başlatma, düzenleyici olarak L2 kayıp fonksiyonu
- Her konvolüsyonel katmandan sonra Batch Normalleştirme
- Biri etiketleme biri tahmin için olan iki farklı çıktı katmanı



Deney Veri Seti

UK-DALE


- UK-DALE veri seti ile çalışılmıştır.
- 2007-2017 yılları arasındaki 5 evin 6 yıllık cihaz bazlı ve toplam ölçüm değerleri bulunmaktadır.
- 52 farklı cihaz verisi (buzdolabı, çamaşır makinesi, bulaşık makinesi, dizüstü bilgisayar, su ısıtıcısı vb.) vardır.
- Her evdeki cihazlar aynı değildir.
- Ortak cihazlar için 3 ev verisi ile öğrenme seti kurulmuş, 1 ev verisi ile test edilmiştir.
- Seçilen cihazlar: çamaşır makinesi, bulaşık makinesi, buzdolabı, kombi ve kettle
- Etiketleme için; F1 score, precision ve recall performans metrikleri kullanılırken, tüketim tahmini için ortalama mutlak hata (MAE) kullanılmıştır.

$$\frac{1}{N} \sum_{i=1}^N |y - x|$$

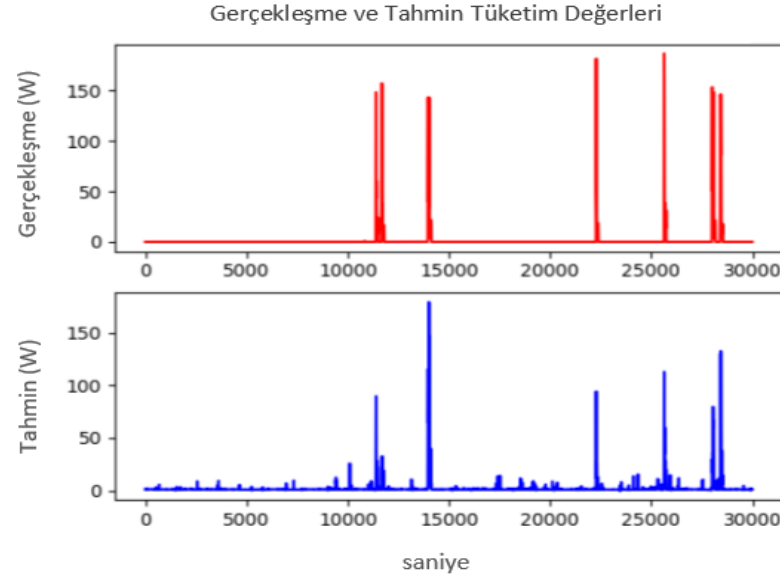
Deney Sonuçları

Evlerde Tüketim Ayırıştırması - Konvolüsyonel Sinir Ağı


- Model Kayıp Değeri: 583.605
- Model Mutlak Hata: 1.722



Çamaşır Makinesi için Etiketleme Modeli



Çamaşır Makinesi için Tüketim Tahmini

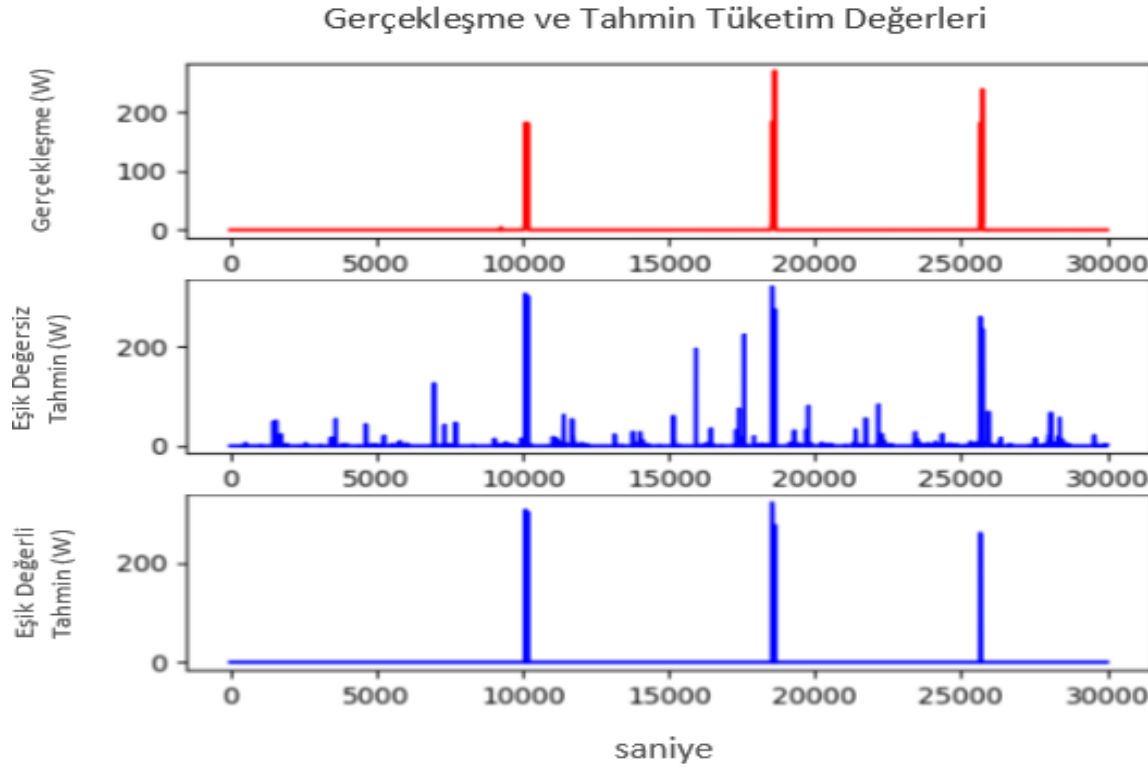


Kombi için Tüketim Tahmini

Deney Sonuçları

Evlerde Tüketim Ayırıştırması - Konvolüsyonel Sinir Ağı

- Her bir çalışma döngüsünde benzer enerji tüketimi davranışı olan cihazlar için modele eşik değeri eklenmiştir. Bulaşık makinesi gibi cihazlarda, çekilen güç kullanımının pik güç kullanımının %80'inden fazla değişmemesi gerektiği varsayılmıştır.



Bulaşık Makinesi için Tüketim Tahmini

Kaynakça

- [1] International Energy Agency, World Energy Outlook 2018, White Paper, IEA, 2015.
- [2] David J C MacKay. Sustainable Energy - without the hot air. UIT Cambridge, UK, 2008.
- [3] International Electrotechnical Commission, Report to WTO TBT Committee, White Paper, IEC, 2017.
- [4] Tsuyoshi Ueno, Ryo Inada, Osamu Saeki, and Kiichiro Tsuji. Effectiveness of an energy consumption information system for residential buildings. *Applied Energy*, 83(8):868-883, 2006.
- [5] H. Kim, M. Marwah, M. Arlitt, G. Lyon, J. Han, Unsupervised disaggregation of low frequency power measurements, Proceedings of the 11th SIAM International Conference on Data Mining, SDM 2011, 2011, pp. 747-758.
- [6] T. Schwartz, S. Deneff, G. Stevens, L. Ramirez, V. Wulf, Cultivating energy literacy: results from a longitudinal living lab study of a home energy management system, Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, ACM, Paris, 2013.
- [7] B. Najafi, S. Moaveninejad, F. Rinaldi, Chapter 17 - Data Analytics for Energy Disaggregation: Methods and Applications, *Big Data Application in Power Systems*, 2018, pp. 377-408.
- [8] Hart, G.W., Kern, E. C. & Schweppe, F. C. 1989. Non-intrusive appliance monitor apparatus. Google Patents.
- [9] G.W. Hart, Nonintrusive appliance load monitoring, *Proc. IEEE* 80 (1992) 1870-1891.
- [10] G.W. Hart, Prototype nonintrusive appliance load monitor, MIT Energy Laboratory and Electric Power Research Institute, 1985.
- [11] J. Kelly and W. Knottenbelt. The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes. *Scientific Data*, 2(150007), 2015.
- [12] N. Amirach, B. Xerri, B. Borloz, and C. Jauffret. A new approach for event detection and feature extraction for nilm. *Electronics, Circuits and Systems (ICECS) IEEE International Conference*, 2014.
- [13] S. B. Leeb, S. R. Shaw, and J. L. Kirtley Jr. Transient event detection in spectral envelope estimates for nonintrusive load monitoring.
- [14] D. G. Lowe. Object recognition from local scale-invariant features. *Computer vision*, 1999. The proceedings of the seventh IEEE international conference, 2(10), 1999.

Kaynakça

- [15] Alex Krizhevsky and Sutskever, Ilya and Hinton, Geoffrey E. Imagenet classification with deep convolutional neural networks. pages 1097–1105, 2012.
- [16] L. Mauch and B. Yang. A new approach for supervised power disaggregation by using a deep recurrent lstm network. In proceedings of the 3rd IEEE Global Conference on Signal and Information Processing (GlobalSIP), pages 63 - 67, 2015.
- [17] L. Mauch and B. Yang. A novel dnn-hmm-based approach for extracting single loads from aggregate power signals. In proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), page 2384-2388, 2016.
- [18] W. He and Y. Chai. An empirical study on energy disaggregation via deep learning. The 2016 2nd International Conference on Artificial Intelligence and Industrial Engineering (AIIE2016), Beijing, ChinaNov., 2016.
- [19] J. Kelly and W. Knottenbelt. Neural nilm: Deep neural networks applied to energy disaggregation. arXiv, 2015.
- [20] K. He, X. Zhang, S. Ren, and J. Sun. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV), ICCV '15, pages 1026–1034, Washington, DC, USA, 2015. IEEE Computer Society.
- [21] S. Ioffe and C. Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In Proceedings of the 32Nd International Conference on International Conference on Machine Learning- Volume 37, ICML'15, pages 448–456. JMLR.org, 2015.
- [22] D. P. Kingma and J. Ba. Adam: A method for stochastic optimization. CoRR, abs/1412.6980, 2014.
- [23] J. Z. Kolter and T. Jaakkola. Approximate Inference in Additive Factorial HMMs with Application to Energy Disaggregation. In Proceedings of the 15th International Conference on Artificial Intelligence and Statistics, pages 1472{1482, La Palma, Canary Islands, 2012.
- [24] I. J. Goodfellow, D. Warde-Farley, M. Mirza, A. Courville, and Y. Bengio. Maxout networks. In Proceedings of the 30th International Conference on International Conference on Machine Learning- Volume 28, ICML'13, pages III– 1319–III–1327. JMLR.org, 2013.
- [25] S. Hochreiter and J. Schmidhuber. Long short-term memory. Neural Comput., 9(8):1735–1780, Nov. 1997.
- [26] D. Bahdanau, K. Cho, and Y. Bengio. Neural machine translation by jointly learning to align and translate. CoRR, abs/1409.0473, 2014.

Teşekkürler

AUSTRALIA

Level 3, 155 Queen St.
Brisbane 4000

INDIA

RMZ Latitude
Commercial,
10th Floor,
Bellary Road,
Hebbal, Bangalore

USA

44 Tehama St,
San Francisco,
CA94105

TURKEY

Inonu Mahallesi,
1748. Sokak, No: 1,
Yenimahalle-Ankara